

DÉPARTEMENT DE GÉOGRAPHIE ET TÉLÉDÉTECTION

Faculté des lettres et sciences humaines

Université de Sherbrooke

**Prédiction des rendements agricoles du maïs et du soya, et
du déficit en azote du maïs à l'aide d'images aéroportées
et d'un réseau de neurones à rétropropagation**

Par

Sérélé Zogbo Charles

**Thèse présentée pour l'obtention du grade de Philosophiae Doctor (Ph. D.)
en Télédétection**

Février 2002

© Sérélé Zogbo Charles

BIBLIOTHÈQUE UNIVERSITÉ DE SHERBROOKE

À LA MÉMOIRE DE

Ma tante Joséphine

Ma nièce Ursule

Mes sœurs Jeannette et Antoinette

COMPOSITION DU JURY

Cette thèse a été évaluée par un jury composé des personnes suivantes :

Hugh Gwyn, Directeur de recherche

(Département de Géographie et Télédétection - Université de Sherbrooke)

Johanne Boisvert, Codirectrice de recherche

(Centre de Recherche et de Développement sur les Sols et les Grandes Cultures -
Agriculture et Agroalimentaire Canada - Ste-Foy)

François Cavayas, Examineur externe

(Département de Géographie - Université de Montréal)

Ferdinand Bonn, Examineur interne

(Département de Géographie et Télédétection - Université de Sherbrooke)

Richard Fournier, Examineur interne

(Département de Géographie et Télédétection - Université de Sherbrooke)

Remerciements

Je remercie mon directeur de thèse, le Professeur Hugh Gwyn pour son aide constante, à la fois morale et scientifique, et pour la confiance dont il a fait preuve à mon égard.

Je tiens à exprimer ma reconnaissance à ma codirectrice de thèse, Docteure Johanne Boisvert pour ses précieux conseils et pour m'avoir fait profiter de sa grande expérience dans les applications agricoles de la télédétection.

Mes remerciements vont également à tous les membres du jury pour le temps et l'intérêt qu'ils ont accordés à ma thèse.

Toute ma reconnaissance aux professeurs, aux amis(ies), étudiants(tes) et au personnel du CARTEL et du Département de géographie et télédétection pour leur collaboration. Mention spéciale au Docteur Alain Royer pour avoir corrigé des chapitres de ma thèse, au professeur Goze Béné pour son soutien scientifique et logistique durant cette thèse, et à M^{me} Micheline Prévost qui a révisé mes nombreux manuscrits, scientifiques ou non.

Je voudrais remercier les responsables d'Agriculture et agroalimentaire Canada pour l'intérêt qu'ils ont accordé à mon projet de recherche et pour avoir mis à ma disposition l'ensemble des données utilisées dans cette thèse.

Je remercie également le Ministère de la Recherche Scientifique de la République de Côte d'Ivoire dont le soutien financier m'a permis d'effectuer mes études doctorales.

Mes remerciements sont également adressés à toutes les personnes qui, de près ou de loin, m'ont aidé dans la réalisation de cette thèse.

Je tiens enfin à exprimer ma profonde gratitude à ma famille, en particulier à mon frère et son épouse, M. et M^{me} Bouabré, ainsi qu'à ma mère Séri Yohou Viviane pour leur soutien sans faille, aussi bien moral que financier à tous les niveaux de mes études.

Résumé

La présente thèse traite de l'utilisation de la télédétection et du réseau de neurones multicouche (MLP) pour la prédiction des rendements du maïs et du soya, et du déficit en azote du maïs. Nous y évaluons le potentiel du MLP comme outil de prédiction et de diagnostic pour aider les producteurs¹ agricoles à faire de meilleurs choix de gestion de leurs fermes.

Les résultats de cette étude montrent que le MLP est capable de modéliser correctement les relations entre les rendements agricoles, les indices de végétation et de texture, et les paramètres de topographie. Sa performance est plus élevée lorsque ces indicateurs sont utilisés conjointement. Il a prédit les rendements du maïs et du soya avec des coefficients R^2 moyens de 92 % et 43 % respectivement pour deux images combinées. La faible sensibilité des photographies aériennes aux variations subtiles des réflectances des cultures relativement aux images multispectrales AISA (*Airborne imaging spectrometer applications*) explique les basses valeurs de R^2 dans le cas du soya.

La thèse indique également que le contenu en information d'une image est plus élevé lorsque celle-ci est acquise durant la période où la croissance végétale est maximale. Ainsi, le MLP développé sur l'image de la mi-saison (juillet) a permis de prédire les rendements du maïs et du soya avec des R^2 moyens respectifs de 89 % et 40 %. Le degré de corrélation entre les intrants et les extrants, et la qualité des données issues des capteurs des rendements jouent donc un rôle très important, car ils déterminent la performance du MLP. Le pouvoir de prédiction de ce modèle a baissé jusqu'à 45 % et 36 % respectivement pour le maïs et le soya lorsque nous avons utilisé les données de rendements non corrigées.

Le MLP a également démontré un grand potentiel de discrimination entre des parcelles de maïs traitées avec différentes doses d'azote. Pour une configuration de MLP basée sur les informations spectrales et texturales, le coefficient Kappa était de 72 % pour l'image AISA de la mi-saison et de 81 % pour les deux images AISA combinées. L'apport de la topographie a augmenté ces coefficients respectivement à 90 % et 95 %. Cela montre que les paramètres de topographie peuvent être très utiles pour différencier des classes de végétation en milieu agricole.

La première contribution de cette thèse est d'avoir démontré la possibilité d'utiliser le MLP comme outil de prédiction et de diagnostic des problèmes de croissance des cultures, afin fournir une assistance aux producteurs agricoles. La pertinence de cette approche est de leur permettre d'entreprendre des actions correctives avant que le stress végétal détecté ne cause une diminution significative de leurs récoltes. La seconde contribution repose sur le développement d'un algorithme de correction des données issues des capteurs de rendements agricoles. Enfin, nous avons montré dans cette thèse que l'analyse discriminante était la mieux adaptée pour la sélection des intrants du MLP.

¹ Dans ce document, le générique masculin désigne aussi bien les femmes que les hommes. Cette décision ne présume d'aucune discrimination.

Abstract

In agriculture, early estimates of the final yield and monitoring of crop nitrogen status are of general interest. Since yield data and nitrogen detection may be used both for the determination of management inputs and to evaluate the results of management strategies, it is important to consider the accuracy of their prediction methods. This thesis explores the suitability of the multi-layer perceptron (MLP) neural network for prediction of corn and soybean yield and for classification of nitrogen corn stressed vegetation. Although the MLP has been used a lot to solve various problems in agriculture, few authors deal with crop yield and nitrogen status prediction using airborne remote sensing and elevation data.

The results show while using a combination of vegetation and texture indices, and topographic data, we can successfully predict corn yield with MLP. The regression coefficient between observed and predicted yield for corn and soybean were respectively 92 % and 43 % for the middle season image only. The weak sensitivity of aerial photographs to the variations of the plant physiology compared to the multispectral AISA (*Airborne imaging spectrometer applications*) images explains the low R^2 coefficients for soybean.

This research also indicates that the information from an image is more important when it is acquired during the period of maximum crop biological activity. Thus, MLP developed on the middle season predicts the corn and soybean yield with respective R^2 of 89 % and 40 %. The degree of relationship between the inputs and the outputs and the quality of the data are very important, because they determine the capabilities of the MLP. When the generalization capabilities of the MLP models were tested on a non-corrected crop yield dataset, the results drop to 45 % and 36 % for corn and soybean respectively.

The MLP demonstrated also its capability to discriminate corn nitrogen status during the growing season. MLP models based on image spectral and textural indices reach a Kappa coefficient of 72 % for middle season image and 81 % for the combined multirate images. Image texture features also provide useful complementary information for the discrimination of different nitrogen stress levels. The best MLP for predicting corn nitrogen status was the one that integrates image features and topographic parameters. It outperforms the first one with an accuracy of 90 % for middle season image and 95 % for all two images. Evidence that topographic data are a critical discriminatory information source is both obvious and strong. In consequence, crop physiological status monitoring systems require taking into account the combined effects of soil background and canopy architecture.

This thesis have highlighted that MLP has a strong potential for detecting corn nitrogen stressed vegetation and that they would help farmers to better manage crop status during the growing season, when there is still time to respond to problems. The other contributions of this study are the development of crop yield data correction and filtering algorithm and the identification of discriminant analysis as the best method for the MLP inputs selection.

Table des matières

Rémerciements	iv
Résumé	v
Abstract	vi
Table des matières	vii
Liste des figures	x
Liste des tableaux	xii
Liste des annexes	xiii
Liste des sigles	xiv

Chapitre I : Introduction générale

1.1 Généralités	1
1.2 Problématique	3
1.3 Objectifs de la recherche	6
1.4 Hypothèses de recherche	7
1.5 Organisation de la thèse	7

Chapitre II : Application du réseau de neurones en agriculture

2.1 Introduction	8
2.2 Architecture d'un réseau de neurones	9
2.3 Règles d'activation des neurones	10
2.4 Règles d'apprentissage du réseau MLP	13
2.5 Configuration de l'architecture du MLP	18
2.5.1 Sélection des intrants	18
2.5.2 Neurones internes et validation croisée	20
2.6 Réseaux de neurones en agriculture	22

2.6.1	Extraction des variables agronomiques	22
2.6.2	Surveillance des conditions phénologiques des cultures	26
1.5	Conclusion	27
Chapitre III : Méthodologie de recherche et traitements des données		
3.1	Introduction.....	28
3.2	Méthodologie de recherche.....	28
3.3	Sites d'études et description des données	31
3.3.1	Sites d'études	31
3.3.2	Données de télédétection	32
3.3.3	Données de rendement agricole	32
3.3.4	Données physico-chimiques du sol.....	33
3.3.5	Cas des parcelles fertilisées en azote	33
3.4	Traitements et analyses des données.....	36
3.4.1	Images AISA et photographies aériennes	36
3.4.2	Algorithme de correction des rendements agricoles.....	40
3.4.3	Analyse géostatistique	52
3.4.4	Autres données disponibles.....	56
3.5	Conclusion	56
Chapitre IV: Variabilité spatiale des rendements agricoles et des images aéroportées		
4.1	Introduction.....	58
4.2	Statistiques descriptives des rendements	59
4.3	Facteurs explicatifs des variations de rendements	61
4.4	Relation entre les rendements et les images	63
4.4.1	Indices de végétation.....	63
4.4.2	Indices de texture	67
4.4.3	Regressions multiples entre les rendements et les indices.....	70
4.5	Conclusion	75
Chapitre V : Indicateurs spectraux et texturaux du déficit en azote du maïs		
5.1	Introduction.....	77
5.2	Variation temporelle de l'indice foliaire.....	78
5.3	Variation des rendements du maïs	80

5.4	Analyse des signatures spectrales du maïs.....	83
5.4.1	Spectres de réflectance mesurés à l'aide du GER.....	83
5.4.2	Spectres de réflectance extraits des images AISA.....	86
5.5	Relation entre le LAI et la signature spectrale.....	88
5.6	Discrimination des parcelles de maïs par les indices.....	91
5.7	Conclusion	95

Chapitre VI : Prédiction des rendements du maïs et du soya à l'aide du MLP

6.1	Introduction.....	96
6.2	Développement et performance du MLP	97
6.3	Réduction de la dimension des intrants du MLP	99
6.4	Prédiction des rendements agricoles par le MLP.....	100
6.5	Analyse de la sensibilité du MLP	107
6.6	Conclusion	111

Chapitre VII : Détection du déficit en azote du maïs à l'aide du MLP

7.1	Introduction.....	113
7.2	Évaluation de la performance du MLP	114
7.3	Réduction de la dimension des intrants du MLP	116
7.4	Détection du stress en azote du maïs à par le MLP	117
7.5	Conclusion	125

Chapitre VIII : Contributions et recommandations

Références bibliographiques

Annexes

Liste des figures

Figure 2.1 : Architecture du réseau MLP.....	10
Figure 2.2 : Structure d'une unité de traitement du MLP	11
Figure 2.3 : Représentation graphique de la fonction sigmoïde	12
Figure 2.4 : Performance du RN selon le nombre de neurones internes.....	21
Figure 2.5 : Validation croisée durant l'apprentissage du réseau	22
Figure 3.1 : Schéma conceptuel du projet de recherche	30
Figure 3.2 : Grille d'échantillonnage du sol dans le champ de maïs	34
Figure 3.3 : Grille d'échantillonnage du sol dans le champ de soya	34
Figure 3.4 : Parcelles de maïs fertilisées avec différentes doses d'azote.....	35
Figure 3.5 : Variations du LAI dans le champ de maïs	37
Figure 3.6 : Variations temporelles du NDVI dans le champ de soya.....	37
Figure 3.7 : Organigramme de l'algorithme de corrections des rendements agricoles ...	42
Figure 3.8 : Détermination du délai avant (d.av.) des rendements du maïs.....	45
Figure 3.9 : Détermination du délai arrière (d.ar.) des rendements du maïs.....	45
Figure 3.10 : Filtrage des rendements du maïs pour un parcours	49
Figure 3.11 : Filtrage des rendements du soya pour un parcours	49
Figure 3.12 : Déviations des points SPG pour un parcours	51
Figure 3.13 : Semivariogramme des rendements du maïs	53
Figure 3.14 : Semivariogramme des rendements du soya	53
Figure 3.15 : Variation des corrélations entre le NDVI et les rendements	55
Figure 4.1 : Carte des rendements du maïs.....	60
Figure 4.2 : Carte des rendements du soya	60
Figure 4.3 : Droite des sols nus dans le champ de maïs	64
Figure 4.4 : Contours des rendements du maïs superposés au WdVI.....	65
Figure 4.5: Contours des rendements du soya superposés au SAVI.....	67
Figure 4.6 : CV du HOM en fonction de la taille de fenêtre pour le maïs.....	68
Figure 4.7 : CV du HOM en fonction de la taille de fenêtre pour le soya	68
Figure 4.8 : Régression entre les rendements du maïs, les IV et les IT (juillet)	71
Figure 4.9 : Régression entre les rendements du maïs et les indices (juillet et sept.).....	72

Figure 4.10 : Régression entre les rendements du soya les indices (juillet)	74
Figure 4.11 : Régression entre les rendements du soya les indices (juillet et sept.)	74
Figure 5.1 : Variations du LAI dans les parcelles fertilisées en azote	79
Figures 5.2 : Relation entre les rendements du maïs et le LAI	82
Figure 5.3 : Spectres du maïs dans les parcelles d'azote	85
Figure 5.4 : Spectres du maïs extraits de l'image AISA du 21 juillet	87
Figure 5.5 : Spectres du maïs extraits de l'image du 13 septembre.....	87
Figure 5.6 : Variations du LAI et des indices spectraux du GER.....	89
Figure 5.7 : Variations du WDV dans les parcelles fertilisées (21 juillet).....	92
Figure 5.8 : Variations du HOM dans les parcelles fertilisées (21 juillet)	94
Figure 6.1 : Schéma de prédiction des rendements du maïs et du soya.....	97
Figure 6.2 : Prédiction des rendements du maïs par le MLP3 _{ADS} (juillet-septembre)	101
Figure 6.3 : Prédiction des rendements du maïs par le MLP3 _{ACP} (juillet-septembre)	101
Figure 6.4 : Prédiction des rendements du soya par le MLP3 _{ADS} (juillet-septembre)	103
Figure 6.5 : Prédiction des rendements du soya par le MLP3 _{ACP} (juillet-septembre)	103
Figure 6.6 : Prédiction des rendements du maïs par le MLP3 _{ADS} (juillet).....	105
Figure 6.7 : Prédiction des rendements du soya par le MLP3 _{ADS} (juillet).....	105
Figure 6.8 : Prédiction des rendements du maïs par le MLP3 _{ADS} (données originales) .	110
Figure 6.9 : Prédiction des rendements du soya par le MLP4 _{ADS} (données originales) .	110
Figure 7.1 : Variation des taux de classification des parcelles fertilisées durant la phase de test des modèles MLP3 et MLP4	119
Figure 7.2 : Variation des taux de classification des parcelles fertilisées selon l'apport (MLP4) ou non (MLP3) de la topographie (juillet)	123
Figure 7.3 : Taux de classification des parcelles d'azote lors de la phase de test du MLP3 (juillet et juillet - septembre)	123

Liste des tableaux

Tableau 3.1 : Filtrage des rendements du maïs pour un parcours.....	48
Tableau 3.2 : Filtrage des rendements du soya pour un parcours	48
Tableau 4.1 : Statistiques des rendements dans l'ensemble du champ	59
Tableau 4.2 : Moyennes des classes de rendements agricoles.....	59
Tableau 4.3 : Régressions multiples entre les rendements et les éléments du sol	62
Tableau 4.4 : Moyennes des indices de végétation du champ de maïs.....	65
Tableau 4.5 : Moyennes des indices de végétation du champ de soya.....	66
Tableau 4.6 : Moyennes des indices de texture du champ de maïs	70
Tableau 4.7 : Moyennes des indices de texture du champ de soya.....	70
Tableau 4.8 : Régression entre les rendements du maïs, les IV et les IT.....	73
Tableau 4.9 : Régression entre les rendements du soya, les IV et les IT	74
Tableau 5.1 : Moyennes du LAI dans les parcelles fertilisées en azote	79
Tableau 5.2 : Statistiques descriptives des zones fertilisées en azote.....	80
Tableau 5.3 : Corrélations entre le LAI et les IV extraits du GER.....	88
Tableau 5.4 : Corrélations entre le LAI et les indices extraits de l'image AISA	90
Tableau 5.5 : Moyennes des indices spectraux extraits des images AISA	92
Tableau 5.6 : Moyennes des indices texturaux extraits des images AISA	94
Tableau 6.1 : Prédiction des rendements du maïs (juillet-septembre)	101
Tableau 6.2 : Prédiction des rendements du soya (juillet-septembre).....	103
Tableau 6.3 : Prédiction des rendements du maïs à l'aide de l'image du 21 juillet.....	104
Tableau 6.4 : Prédiction des rendements du soya à l'aide de l'image du 30 juillet.....	104
Tableau 6.5 : Apport de la topographie aux performances du réseau MLP4	106
Tableau 6.6 : Statistiques des rendements agricoles avant et après correction.....	109
Tableau 6.7 : Prédiction du MLP avant et après correction des rendements (juillet) ...	109
Tableau 7.1 : Précisions de la classification des parcelles fertilisées (apprentissage) ...	118
Tableau 7.2 : Précisions de la classification des parcelles fertilisées (test)	118
Tableau 7.3 : Précisions de la classification des parcelles fertilisées (apprentissage) ...	121
Tableau 7.4 : Précisions de la classification des parcelles fertilisées (test)	121

Liste des annexes

Annexe 3A : Statistiques descriptives des propriétés du sol (maïs)	145
Annexe 3B1 : Statistiques descriptives des propriétés du sol (soya).....	145
Annexe 3B2 : Mesures d'indices foliaires dans le champ de maïs.....	145
Annexe 4A : Carte des élévations du champ de maïs.....	146
Annexe 4B: Carte des élévations du champ de soya.....	146
Annexe 4C : Corrélations entre les rendements du maïs et les paramètres du sol.....	147
Annexe 4D : Corrélations entre les rendements du soya et les paramètres du sol.....	147
Annexe 4E : Modèles de régression multiple entre les rendements et les réflectances..	148
Annexe 4F : Corrélations entre les rendements du maïs, les IV et IT (juillet)	149
Annexe 4G : Corrélations entre les rendements du maïs, les IV et IT (septembre)	149
Annexe 4H : Corrélations entre les rendements du soya, les IV et IT (juillet).....	149
Annexe 4I : Corrélations entre les rendements du soya, les IV et IT (septembre).	150
Annexe 5A : Analyse de variance des zones d'azote (juillet)... ..	150
Annexe 5B : Analyse de variance des zones d'azote (septembre).....	151
Annexe 6A : Extraction des composantes principales (juillet - septembre - maïs)... ..	152
Annexes 6B : Extraction des composantes principales (juillet - septembre - soya)	153
Annexe 6C: Sélection des variables à l'aide de l'ADS (juillet - maïs).....	154
Annexe 6D : Sélection des variables à l'aide de l'ADS (juillet - septembre -maïs).....	155
Annexe 6E: Sélection des variables à l'aide de l'ADS (juillet - soya).....	156
Annexe 6F: Sélection des variables à l'aide de l'ADS (juillet - septembre - soya).....	157
Annexe 6G : Statistique Z des R^2 entre les rendements prédits et observés.....	158
Annexe 7A: Extraction des composantes principales (juillet - septembre).....	159
Annexe 7B : Sélection des variables à l'aide de l'ADS (juillet - septembre)).....	160
Annexe 7C: Sélection des variables à l'aide de l'ADS (juillet)).....	161
Annexe 7D : Test Z sur les coefficients Kappa).....	162

Liste des sigles

AAC	Agriculture et agroalimentaire Canada
ACP	Analyse en composantes principales
ADS	Analyse discriminante séquentielle
AISA	Airborne imaging spectrometer applications
ART	Adaptative resonance theory
Ca	Calcium
CEC	Capacité d'échange cationique
CERES	Crop environment resource systems
CMAC	Cerebella model articulation controller
CON	Contraste
CP	Composantes principales
CV	Coefficient de variation
ENT	Entropie
EPIC	Erosion productivity impact calculator
ETM	Enhanced thematic mapper
GC	Gradient conjugué
GER	Geophysical and environmental research
HOM	Homogénéité
IEM	Integral equation model
ISODATA	Iterative self-organizing data analysis
IT	Indices de texture
IV	Indices de végétation
K	Potassium
LAI	Leaf area index
Mg	Magnésium
MIMICS	Michigan's microwave canopy scattering model
MLP	Multilayer perceptron
MO	Matière organique
MSAVI	Modified soil adjusted vegetation index

MTM	Mercator transverse modifiée
N	Azote
NDVI	Normalized difference vegetation index
P	Phosphore
RDS	Rural development system
RMS	Root mean square
RN	Réseaux de neurones
RP	Rétropropagation
SAIL	Scattering by arbitrary inclined leaves
SAVI	Soil adjusted vegetation index
SeaWiFS	Sea-viewing Wide Field of view Sensor
SIG	Systèmes d'informations géographiques
SMA	Second moment angulaire
SPG	Système de positionnement par satellite
SUCROS	Simple universal crop growth simulator
TM	Thematic mapper
TSARVI	Transformed soil adjusted vegetation index
UTM	Universal transversal mercator
WDVI	Weighted difference vegetation index

Chapitre I

Introduction générale

1.1 Généralités

Le taux de croissance élevé de la population mondiale crée une demande alimentaire de plus en plus grande. Pour satisfaire une telle demande, il est nécessaire de mettre au point des méthodes de gestion agricole plus efficaces pour mieux contrôler l'impact des facteurs environnementaux sur le développement des cultures et ainsi optimiser la production agricole.

La majorité des sols agricoles n'est pas homogène. Ces sols présentent des variations spatiales importantes dans leurs propriétés physico-chimiques. Celles-ci induisent différentes conditions de fertilité qui occasionnent une croissance non uniforme des cultures à l'intérieur d'un même champ (Stafford *et al.*, 1996). La conséquence immédiate est la baisse des rendements, ainsi qu'une dépréciation de leur qualité. En dépit de cette hétérogénéité des sols, les agriculteurs traitent l'ensemble de leurs champs de la même manière en y appliquant uniformément la même quantité et souvent le même type de fertilisant. Une telle pratique culturale entraîne une sur-fertilisation des zones du champ qui présentent une faible demande en éléments nutritifs, alors que les secteurs qui souffrent d'un déficit demeurent sous fertilisés. D'un point de vue environnemental, la

sur-fertilisation augmente le risque de pollution, car l'azote non utilisé par les plantes peut contaminer les ressources en eau et contribuer à l'effet de serre (Pierce, 1997).

Depuis quelques années, une nouvelle approche dénommée agriculture de précision tente de remédier aux problèmes associés à l'agriculture traditionnelle. Elle préconise la prise en compte de la capacité productive de chaque type de sol à l'intérieur d'un champ afin d'y adapter les pratiques culturales (Murphy *et al.*, 1995). Cela revient à quantifier la variabilité spatiale du sol en subdivisant celui-ci en plusieurs unités homogènes pouvant être gérées individuellement et efficacement. Cette approche a pour but d'augmenter la production agricole et d'optimiser l'utilisation des intrants à la ferme.

Le succès de l'agriculture de précision repose sur le développement des technologies telles que les capteurs de rendement, les systèmes de positionnement global (SPG), les systèmes d'information géographiques (SIG) et la télédétection (Yang *et al.*, 1998). La combinaison du capteur de rendement et du SPG est plus courante en agriculture. Elle donne la possibilité de générer des cartes de rendement qui permettent de localiser les endroits de faible et de forte productivité et de préciser l'amplitude de leurs variations à l'intérieur du champ. Mais ces cartes sont produites seulement en fin de saison quand il n'est plus possible de rectifier les effets des facteurs limitant la croissance des cultures pour l'année en cours. Les agriculteurs ont surtout besoin d'informations qui leur permettent de gérer leurs champs en cours de saison culturale. Ils pourraient ainsi apporter des correctifs directement dans les zones du champ qui présentent des problèmes quelconques de croissance.

L'objectif de cette thèse est de vérifier si l'intégration de la télédétection avec les techniques de l'intelligence artificielle telles que les réseaux de neurones (RN), peut permettre de prédire correctement la réponse des cultures aux contraintes imposées par leurs environnements et de mettre en évidence la variabilité spatiale des rendements agricoles durant la saison agricole.

Dans la suite de ce chapitre, nous présentons d'abord la problématique dans laquelle nous soulignons les limites des méthodes actuelles de gestion agricole, ensuite les objectifs, les hypothèses et l'organisation générale de la thèse.

1.2 Problématique

Pour assurer une protection efficace de ses cultures, l'agriculteur devrait disposer d'un outil qui lui permette de dépister la présence et la distribution spatiale des problèmes liés aux stress végétaux, et de prédire ses récoltes en cours de saison. De telles informations permettent d'apporter des correctifs directement aux endroits affectés et de gérer efficacement la production finale. Les méthodes actuelles d'évaluation des stratégies de gestion agricole sont parfois mal adaptées aux réalités du terrain ou encore très complexes à mettre en œuvre (Rudorff and Batista, 1991).

L'avènement des capteurs de rendement permet de mesurer les variations spatiales des rendements agricoles à l'échelle du champ. On distingue deux types de capteurs utilisés lors de la récolte des grains : le premier mesure la masse à partir de la force d'impact des grains sur un détecteur en forme de plaque et le second mesure le volume des grains à partir d'un rayon infrarouge projeté au travers de l'élévateur (Montour, 1997). La quantité de lumière obstruée par ces grains est alors égale au volume de grain transporté. Ce dernier est ensuite converti en masse en tenant compte du poids spécifique du grain et de l'équation d'étalonnage déterminée expérimentalement.

Lorsqu'ils sont bien étalonnés, ces capteurs de rendement peuvent atteindre une précision de l'ordre de 95 % à 99 % sur de grandes surfaces (Pierce, 1997). Cependant, ils sont complexes à utiliser et leur précision dépend fortement de la qualité de cet étalonnage et de la diffusion des grains dans la moissonneuse (Elizabeth Pattey, 2000 - communication personnelle). De plus, les données des capteurs de rendement ne sont disponibles qu'à la fin de la saison agricole, si bien que les informations qu'ils fournissent sont surtout utiles pour la prochaine saison. Ainsi, ils ne répondent pas tout à fait à la préoccupation des agriculteurs, à savoir la bonne information au bon moment et au bon endroit.

Les modèles statistiques sont généralement utilisés pour expliquer les variations spatiales des rendements des cultures (Cambardella *et al.*, 1996; Sudduth *et al.*, 1996). Ces modèles tiennent compte des tendances passées des productions agricoles, des conditions climatiques, pédologiques et des variables biophysiques des plantes. Ces modèles peuvent estimer globalement les rendements agricoles avec une précision de l'ordre de 5 % (Bonn et Rochon, 1992). Toutefois, ces méthodes qui fonctionnent assez bien sur des petites superficies, s'avèrent parfois inefficaces lorsqu'elles sont appliquées sur de grands espaces. De plus, leurs applications nécessitent une distribution normale des intrants (Atkinson and Tatnall, 1997). Or dans la réalité, la violation de cette condition est fréquente, si bien que les résultats obtenus n'ont pas toujours la pertinence escomptée.

Les modèles agrométéorologiques permettent de palier à ce problème par la modélisation des conditions des cultures. On peut citer entre autre, les modèles CERES (*Crop environment resource systems*) (Tsuji and Bala, 1994), EPIC (*Erosion productivity impact calculator*) (Williams *et al.*, 1989) et SUCROS (*Simple universal crop growth simulator*) (Spitters *et al.*, 1989). Ces modèles décrivent les relations entre les processus physiologiques des plantes et les facteurs environnementaux tels que la radiation solaire, la température, l'humidité du sol et la disponibilité en éléments nutritifs. Ils sont capables de simuler le développement des cultures depuis les semis jusqu'à la maturité des plantes.

Bien que les modèles semi-empiriques soient bien établis et qu'ils aient donné de bons résultats dans certains cas, ils présentent un inconvénient majeur. En effet, les relations mathématiques qui décrivent chaque processus modélisé sont issues d'hypothèses simplifiées de la réalité physique. Par conséquent, la précision de tels modèles dépend de la qualité de l'approximation de ces relations, ce qui impose de connaître la nature des interactions entre les variables d'entrée et de sortie (Kenneth *et al.* 1996). Aussi, ces modèles requièrent généralement un grand nombre de variables qui sont spécifiques au site d'étude, et parfois difficiles à obtenir sur le terrain avec une bonne précision. Le coût d'acquisition de ces variables est également à considérer. Enfin, comme le souligne Bouman (1995), les résultats des modèles agrométéorologiques sont souvent biaisés par l'apparition de stress végétaux dont les effets ne sont pas toujours pris en compte.

L'applicabilité des modèles agrométéorologiques a été étendue en les combinant avec les SIG et surtout avec la télédétection, ce qui a permis d'y intégrer la notion d'échelle spatiale et de critères d'aide à la décision (Thorton, 1991; Clevers, 1997; Priya and Shibasaki, 2001). Les possibilités d'application de la télédétection en agriculture ont été démontrées par l'estimation des caractéristiques végétales telles que la teneur en pigments foliaires, la biomasse et surtout l'indice foliaire (LAI - Leaf area index). Ce LAI qui est l'une des variables biophysiques les plus importantes en agriculture est aussi essentiel au fonctionnement de bien des modèles agrométéorologiques (Clevers *et al.*, 1994). Cette variable peut ainsi être mesurée par télédétection et être intégrée directement dans un modèle de croissance ou servir uniquement à le réinitialiser pour améliorer sa performance (Bouman, 1991; Delecolle *et al.*, 1992).

Les variables biophysiques des cultures peuvent également être générées à partir de modèles basés sur la théorie du transfert radiatif² (Kuusk, 1994; Fung, 1994). C'est le cas par exemple des modèles MIMICS (Michigan's microwave canopy scattering model) (Ulaby *et al.*, 1990) et SAIL (Scattering by arbitrary inclined leaves) (Verhoef, 1984). Mais l'extraction des caractéristiques de la végétation à partir de ces modèles complexes exige que ces derniers soient inversés. Or, pour diverses raisons, le processus d'inversion n'est pas toujours aisé ou possible pour la majorité des modèles de transfert radiatif (Polatin *et al.*, 1994; Privette *et al.*, 1996).

De nouvelles techniques de modélisation spatiale non linéaires comme les RN peuvent aider à remédier aux limites précédemment évoquées et faciliter la gestion agricole. En effet, contrairement aux modèles physiques, le fonctionnement des RN n'est pas basé sur des équations mathématiques, et pourtant, ils génèrent d'excellents résultats, même avec un nombre limité de variables (Yang *et al.*, 1996). Ils permettent également de traiter des problèmes pour lesquels on ne dispose d'aucune information sur la distribution des variables d'entrée et peuvent être appliqués sur des données incomplètes (Atkinson and

² La théorie du transfert radiatif décrit les interactions entre les ondes électromagnétiques et un milieu semi-transparent pouvant absorber, réfléchir ou diffuser ce rayonnement. Ils simulent ainsi la variation du signal de télédétection provenant d'un couvert végétal plus ou moins dense limité par un sol sous-jacent opaque (plus ou moins réfléchissant ou absorbant) (Alain Royer, 2001 - Communication personnelle).

Tatnall, 1997). Les RN sont favorables à l'intégration de données multisources et le processus d'adaptation des poids des variables d'entrée leur donne un degré de robustesse qui permet de compenser les variations potentielles de la structure des données. De plus, de nombreuses études ont démontré la possibilité d'inverser les modèles de transfert radiatif à l'aide des RN (Pong *et al.*, 1999; Xianyun *et al.*, 2000).

L'approche que nous proposons dans le cadre de cette thèse met l'accent sur l'utilisation d'images aéroportées à fines résolutions afin de mieux capter les variations spatiales de l'état phénologique des cultures. De ces images, nous avons extrait non seulement des indices de végétation, mais aussi des indices de texture dont l'usage dans le réseau de neurones apporte des informations supplémentaires qui mettent en évidence la variabilité spatiale des rendements agricoles et du déficit en azote.

Bien que les données de fertilité du sol soient pertinentes dans les modèles agricoles, nous ne les avons pas intégrées dans notre approche à cause de leurs coûts et temps d'acquisition. Nous avons plutôt considéré les données topographiques (élévation, pentes et orientation des pentes) qui influencent la variation des rendements agricoles en contrôlant les propriétés de drainage du sol. De plus, ces données sont facilement accessibles.

1.3 Objectifs de la recherche

La finalité de cette thèse est de contribuer au développement d'outils décisionnels en vue d'aider les producteurs à faire des choix de gestion agricole permettant d'optimiser leurs rendements. L'objectif principal de la thèse est d'évaluer le potentiel du réseau perceptron multicouche (Multilayer perceptron, MLP) comme outil de prédiction des rendements et du déficit en azote chez le maïs et le soya.

Les objectifs spécifiques se résument à :

1. Évaluer le potentiel des images aéroportées AISA à caractériser la variabilité spatiale des rendements agricoles et du déficit en azote;
2. Intégrer des données spectrales, texturales et topographiques dans le MLP pour prédire les rendements agricoles et le déficit en azote.

1.4 Hypothèses de recherche

Ce projet de thèse cherche à valider les hypothèses suivantes :

Hypothèse 1 : Une image acquise durant le stade de développement maximum des cultures contient suffisamment d'information spectrale pour prédire les conditions des cultures;

Hypothèse 2 : Un MLP basé des données spectrales, texturales et topographiques permet de prédire les rendements agricoles et le déficit en azote.

1.5 Organisation de la thèse

Cette thèse est subdivisée en huit chapitres dont le premier présente l'introduction générale. Le chapitre 2 traite de la théorie des RN en général et du MLP en particulier et de leurs applications en agriculture. Le chapitre 3 présente la méthodologie de recherche, la description, les traitements et l'analyse des données. Le chapitre 4 évalue le potentiel des indices de végétation (IV) et des indices de texture (IT) à caractériser les variations spatiales des rendements agricoles. Quant au chapitre 5, il met en évidence leurs capacités à discriminer des parcelles de maïs traitées avec différents taux d'azote. Les chapitres 6 et 7 discutent du potentiel du MLP à prédire les rendements du maïs et du soya, ainsi que le déficit en azote du maïs. Enfin, les contributions et recommandations font l'objet du chapitre 8.

Chapitre II

Applications des réseaux de neurones en agriculture

2.1 Introduction

La nouvelle génération des satellites d'observation de la Terre génère une grande quantité de données ayant un contenu en information plus précis et plus détaillé (IKONOS, SPOT-VEGETATION, LANDSAT-ETM, etc.). Ces données améliorent la couverture temporelle, spatiale et spectrale de la surface de la Terre. De plus, elles constituent une ressource considérable pour le suivi des conditions des cultures. Ce type de données présente cependant de grands défis de traitement et d'interprétation. Le développement de nouvelles méthodes efficaces s'impose pour exploiter adéquatement leur contenu en information. C'est dans ce contexte que le réseau de neurones (RN) est utilisé dans une grande variété d'applications en agriculture.

Le RN est une tentative de modélisation du fonctionnement du cerveau humain et du système nerveux (Bishop, 1995). Il est très efficace dans le traitement de grandes quantités de données de différentes sources. Les neurones du cerveau humain reçoivent une série d'informations d'autres neurones et ils génèrent un autre type d'information qui

est transféré à d'autres neurones. Même si le RN ne reproduit pas exactement la complexité du cerveau humain et qu'il est basé sur l'architecture de simples neurones, il a démontré son utilité dans le traitement et l'interprétation des données de télédétection (Atkinson and Tatnall, 1997).

Le RN est généralement caractérisé par trois éléments fondamentaux : l'architecture, les règles d'activation et les règles d'apprentissage. Ces éléments sont développés dans les trois prochaines sections.

2.2 Architecture d'un réseau de neurones

Une revue complète des RN est présentée par Lippman (1987). Dans le cadre de cette étude, nous nous sommes toutefois limités au réseau MLP qui est l'une des méthodes les plus largement étudiées en télédétection (Benediktsson *et al.*, 1990). Ce type de réseau est assez simple à comprendre et relativement facile à utiliser. Il est composé d'un ensemble d'unités de traitement qui s'inspirent du fonctionnement des neurones biologiques. Ces unités aussi appelées neurones sont reliées entre elles par des connexions dont la force est déterminée par des poids. Chacune de ces unités exécute trois principales fonctions : la réception des signaux en provenance des unités voisines, leur sommation et le transfert du nouveau signal aux unités en aval par l'intermédiaire d'une fonction non linéaire.

Le MLP est généralement organisé en trois couches (Figure 2.1) : la couche d'entrée qui reçoit les variables originales, la couche de sortie qui donne l'interprétation du problème par le réseau, et la ou les couches cachées (ou internes) qui traitent et font transiter l'information (Bishop, 1995). Il n'y a pas de lien entre les neurones d'une même couche et la contribution de chacun d'eux est déterminée par son niveau d'activation. Le traitement de l'information se fait toujours dans le même sens, des neurones d'entrée vers les neurones de sortie.




Figure 2.1 : Architecture du réseau MLP (Adapté de Song *et al.*, 1995)

2.3 Règles d'activation des neurones

Chaque neurone du réseau fonctionne comme une unité de calcul autonome qui détermine son état d'activation à partir des informations fournies par les neurones de la couche précédente (Figure 2.2). Les neurones possèdent un niveau d'activation qui leur est associé à chaque instant et dont la force dépend de la quantité d'informations reçue de ses voisins. Si l'activation du neurone i a tendance à accroître celle du neurone j , alors la connexion w_{ji} est dite excitatrice avec un poids positif. Par contre, si l'activation de i tend à diminuer celle de j , la connexion est dite inhibitrice avec un poids négatif (Bourret *et al.*, 1991). Mais un neurone ne transmet pas toujours l'information qu'il reçoit. En effet, le neurone n'est activé que si le potentiel d'activation qu'il reçoit dépasse un certain seuil. Il transmet alors une réponse dont la valeur est celle de son niveau d'activation. Lorsque le neurone n'est pas activé, il ne transmet aucune information à ses voisins.

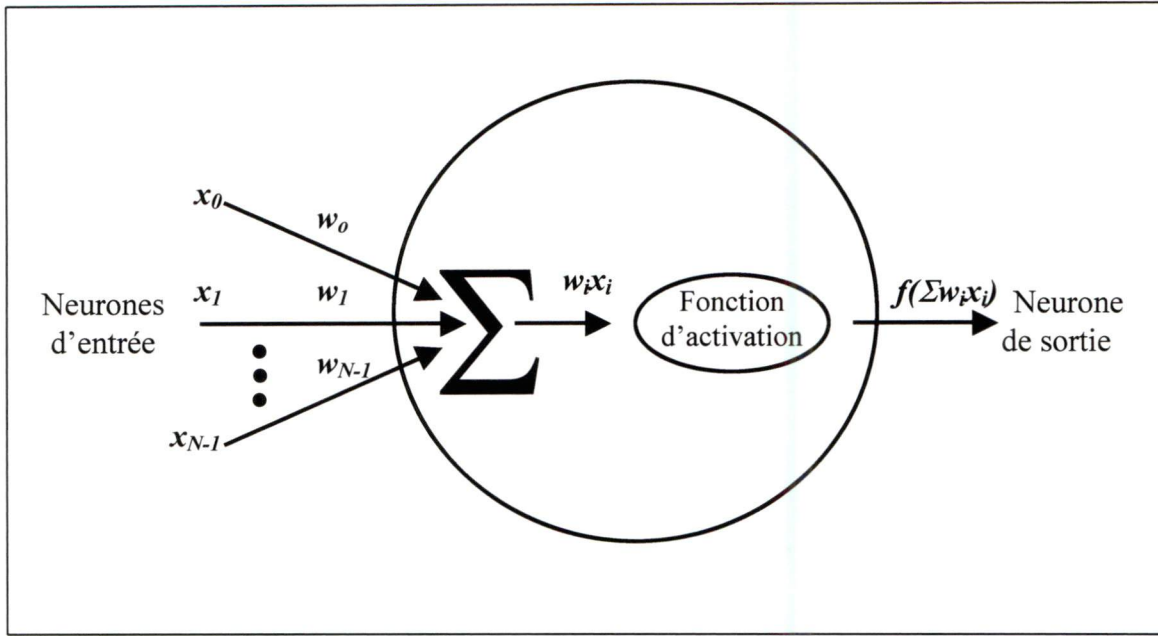


Figure 2.2 : Structure d'une unité de traitement du MLP
(Adapté de Paola *et al.*, 1995)

La somme pondérée des signaux reçus par un neurone est déterminée par la relation suivante (Shearer *et al.*, 1998) :

$$o_{pj} = \sum_i w_{ji} x_{pi} + \theta_j \quad (2.1)$$

où o_{pj} est la somme pondérée des entrées du neurone j , w_{ji} est le poids de connexion entre le neurone actuel j et le neurone précédent i , x_{pi} est la sortie des neurones i connectés au neurone j pour le cas p et θ_j est le biais dont la valeur d'entrée est une constante égale à 1.

Le résultat de l'équation (2.1) est ensuite transformé par une fonction d'activation non linéaire pour déterminer l'état d'activation a_{pj} du neurone j qui sera transféré aux neurones k de la couche suivante. Toutes les fonctions continues et dérivables en tous points de l'espace peuvent être utilisées comme fonctions d'activation (Paola et Schowengardt, 1995).

La fonction d'activation sigmoïde ou logistique est la plus utilisée en télédétection, car elle permet une convergence beaucoup plus rapide du réseau (Figure 2.3). Cette fonction sigmoïde est définie par l'équation (2.2) suivante :

$$a_{pj} = f(o_{pj}) = \frac{1}{1 + e^{-o_{pj}}} \quad (2.2)$$

où a_{pj} est l'état d'activation du neurone j .

La fonction d'activation joue un rôle capital dans le processus d'apprentissage et ses propriétés influencent la performance du réseau. Un choix inadéquat de cette fonction peut nuire aux capacités d'apprentissage et de généralisation du MLP (Tarassenko, 1998).




Figure 2.3 : Représentation graphique de la fonction sigmoïde

2.4 Règles d'apprentissage du réseau MLP

L'apprentissage du RN est une étape de développement au cours de laquelle les paramètres de ce dernier sont ajustés jusqu'à l'obtention du comportement désiré (Tarassenko, 1998). On distingue deux types d'apprentissage : l'apprentissage supervisé dans lequel l'exemple et la réponse attendue sont fournis au RN et l'apprentissage dit non supervisé dans lequel seulement l'exemple est fourni. À la fin de l'apprentissage, les poids de connexions sont fixés et le RN est prêt à être utilisé sur des données indépendantes.

L'apprentissage du réseau MLP est généralement réalisé par l'algorithme de rétro-propagation (RP) du gradient d'erreur qui a été l'un des tous premiers algorithmes d'optimisation des réseaux multicouches (Rumelhart *et al.*, 1986). La méthode de RP est à l'origine de l'essor du réseau MLP longtemps boudé par la communauté scientifique à cause de l'absence d'algorithmes d'optimisation efficaces pour son apprentissage (Charalambous, 1992). Cette méthode est toujours la technique de référence dans différentes applications, particulièrement en télédétection.

L'algorithme du gradient d'erreur fonctionne selon un processus itératif conçu pour minimiser la fonction d'erreur E_p définie par les différences entre les prédictions du réseau et les valeurs observées (Bishop, 1995) :

$$E_p = \frac{1}{2} \sum_k \left(o_{pk} - t_{pk} \right)^2 \quad (2.3)$$

où t_{pk} représente les valeurs observées et o_{pk} correspond aux valeurs prédites par le neurone k pour la paire d'échantillons p .

Pour minimiser cette fonction d'erreur, on calcule la somme de ses dérivées premières par rapport à chaque poids de connexions du réseau et pour chaque paire d'échantillons p .

Une itération de cet algorithme peut être résumée en dix étapes qui sont décrites ci-dessous (Zurada, 1996) :

- **Étape 1 : Initialisation des poids de connexion**

Les poids de connexions entre les neurones et les seuils de chaque neurone sont initialisés d'une manière arbitraire à des valeurs de faible grandeur. Cette initialisation est effectuée au niveau de toutes les couches du RN.

- **Étape 2 : Choix d'un exemple d'apprentissage**

Le réseau fait une sélection séquentielle ou aléatoire d'une paire d'échantillon p dans la base de données d'apprentissage.

- **Étape 3 : Calcul de l'activation des neurones internes**

L'état d'activation de chaque neurone interne est calculé par la relation suivante :

$$a_{pj} = f_j(o_{pj}) \quad (2.4)$$

et

$$o_{pj} = \sum_i w_{ji} x_{pi} + \theta_j \quad (2.5)$$

où a_{pj} est l'état d'activation du neurone j pour la paire d'échantillons p , et w_{ji} représente le poids de connexion entre le neurone i et le neurone j .

- **Étape 4 : Calcul de l'activation des neurones de sortie**

L'activation des neurones de la couche de sortie est calculée de la même manière que les neurones de la couche interne :

$$a_{pk} = f_k(o_{pk}) \quad (2.6)$$

et

$$o_{pk} = \sum_j w_{kj} a_{pj} + \theta_k \quad (2.7)$$

Où a_{pk} est l'état d'activation du neurone k pour la paire d'échantillons p et w_{kj} est le poids de connexion entre le neurone j et le neurone k .

- **Étape 5 : Calcul de l'erreur des neurones de sortie**

L'erreur de chaque neurone de la couche de sortie est déterminée par la relation :

$$\partial_{pk} = (o_{pk} - t_{pk}) f'_k(a_{pk}) \quad (2.8)$$

où ∂_{pk} est l'erreur au niveau du neurone k pour la paire d'échantillons p et $f'_k(a_{pk}) = f(a_{pk})(1 - f(a_{pk}))$ est la dérivée première de la fonction d'activation.

- **Étape 6 : Calcul de l'erreur des neurones internes**

L'erreur correspondant à chaque neurone j de la couche interne est déterminée à partir de l'équation de récurrence suivante qui est basée sur l'erreur de la couche de sortie.

$$\partial_{pj} = \left(\sum_k \partial_{pk} w_{kj} \right) f'_j(a_{pj}) \quad (2.9)$$

Cette manière spécifique de calculer l'erreur interne est due au fait qu'on ignore les sorties des neurones internes. Par conséquent, le terme d'erreur associé aux neurones internes n'est pas connu. Il faut donc exprimer l'erreur de ces neurones à partir de celle des neurones de sortie, seule erreur directement mesurable. Cette particularité justifie

d'ailleurs l'appellation de cet algorithme : algorithme de RP, car l'erreur de la sortie est réinjectée dans le réseau.

- **Étape 7 : Calcul des variations des poids w_{ji}**

La modification de poids Δ_p à apporter aux connexions w_{ji} entre la couche d'entrée et la couche interne est calculée comme suit :

$$\Delta_p w_{ji} = -\alpha_j \partial_{pj} x_{pi} \quad (2.10)$$

où $\Delta_p w_{ji}$ est la variation du poids w_{ji} associé à la paire d'échantillons p , et α_j est le taux d'apprentissage ($0 < \alpha < 1$).

- **Étape 8 : Calcul des variations de poids w_{kj}**

La modification de poids Δ_p à apporter aux connexions w_{kj} entre la couche interne et la couche de sortie est déterminée de la même manière qu'à l'étape 7 :

$$\Delta_p w_{kj} = -\alpha_k \partial_{pk} o_{pj} \quad (2.11)$$

- **Étape 9 : Ajustement des poids de connexions**

Les poids de connexions w_{ji} et w_{kj} sont alors mises à jour respectivement par les relations suivantes :

$$w_{ji}(n+1) = w_{ji}(n) + \Delta_p w_{ji}(n) \quad (2.12)$$

et

$$w_{kj}(n+1) = w_{kj}(n) + \Delta_p w_{kj}(n) \quad (2.13)$$

où n est la $n^{\text{ième}}$ itération.

Les valeurs seuils de chaque neurone sont ajustées de la même manière en les considérant comme des poids d'une connexion qui reçoit une constante en entrée (Lippmann, 1987). De plus, les valeurs des seuils et les poids de connexion ne sont pas modifiés lorsque les prédictions des neurones de sortie sont égales aux valeurs observées.

- **Étape 10 : Fin du cycle de l'apprentissage**

Retour à l'étape 2 et choix d'une nouvelle paire d'échantillons. Cette boucle se poursuit jusqu'à ce que tous les cas de la base d'apprentissage soient traités.

L'amélioration couramment apportée à l'algorithme de RP consiste à ajouter aux relations de l'étape 9, un terme dénommé *momentum* ($0,01 < \eta < 0,1$) dans le but d'accélérer la convergence du réseau :

$$w_{ji}(n+1) = \Delta_p w_{ji}(n) + \eta [w_{ji}(n) - w_{ji}(n-1)] \quad (2.14)$$

et

$$w_{kj}(n+1) = \Delta_p w_{kj}(n) + \eta [w_{kj}(n) - w_{kj}(n-1)] \quad (2.15)$$

En effet, si les poids de connexions sont très élevés, l'état d'activation des neurones se situera dans la zone de saturation de la fonction sigmoïde où les dérivées sont proches de zéro, ce qui ralentit considérablement la procédure d'optimisation (Tarassenko, 1998). Le momentum permet alors de réduire l'amplitude des poids de connexions entre les neurones.

Les potentialités de l'algorithme de RP ont été démontrées dans de nombreuses applications et plus particulièrement en télédétection (Atkinson and Tatnall, 1997; Törmä, 2000). Toutefois, cet algorithme présente quelques inconvénients. Premièrement, il est basé sur la minimisation d'une erreur locale et non d'une erreur globale calculée sur toute la base de données d'apprentissage. Par conséquent, l'algorithme de RP ajuste les poids de connexions sans tenir compte des erreurs et corrections apportées à la paire d'échantillons précédente. Deuxièmement, un apprentissage correct de cet algorithme

exige une détermination expérimentale du taux d'apprentissage (α) et du *momentum* (η) dont des valeurs inadéquates pourraient prolonger le temps de convergence de l'algorithme du gradient.

De nouvelles méthodes d'optimisation telles que les méthodes de Newton, Quasi-newton ou l'algorithme du gradient conjugué (GC) ont été explorées afin d'améliorer la convergence des RN. Le potentiel de ces méthodes a été prouvé dans de nombreux travaux (Johansson *et al.*, 1992; Rosario et Nazif, 1992; Smart van der, 1994). L'algorithme du GC est le plus utilisé dans les applications de télédétection pour pallier les limites du RP (Benediktsson and Swain, 1993). Contrairement à l'algorithme de RP, les directions du gradient ne sont pas spécifiées, mais sont plutôt déterminées à chaque itération. Le vecteur du gradient ainsi calculé est ajouté à la combinaison linéaire des vecteurs de gradients précédents pour obtenir un nouveau vecteur de direction dit conjugué (Luenberger, 1984). La minimisation de l'erreur est globale, c'est-à-dire qu'elle est calculée sur toute la base de données d'apprentissage. Enfin, les coefficients α et η sont automatiquement ajustés par cet algorithme qui sera d'ailleurs utilisé dans cette étude pour l'apprentissage du MLP.

2.5 Configuration de l'architecture du MLP

2.5.1 Sélection des intrants

Les images multispectrales apportent beaucoup d'information sur les objets observés à la surface de la Terre. En théorie, chaque canal apporte une certaine information sur les objets de la scène. Par contre, on remarque que dans beaucoup de cas, certaines bandes apportent presque les mêmes types d'informations. En d'autres termes, il existe souvent une grande redondance, donc une corrélation entre les informations issues des bandes spectrales d'un même capteur. Or, le temps de convergence et la capacité de généralisation du RN sont fortement reliés à la dimension de la base de données d'apprentissage (Bishop, 1995). Il importe alors de réduire le nombre des entrées, mais en ayant comme objectif la performance globale du réseau. La principale question qui se

pose alors est la suivante : comment peut-on réduire le nombre d'intrants du réseau tout en conservant le maximum d'information ? Une méthode de sélection rigoureuse des intrants s'impose afin de n'inclure dans le modèle que les variables pertinentes dont l'apport permet d'optimiser la performance du RN.

Diverses méthodes plus ou moins complexes de sélection des intrants du RN sont proposées dans la littérature (Redondo *et al.*, 1999; Kavzoglu and Paul, 2000). Parmi celles-ci, les méthodes conventionnelles comme l'analyse en composantes principales (ACP) et l'analyse discriminante séquentielle (ADS) sont plus utilisées en télédétection (Wu and Massart, 1996).

L'ACP est une méthode de transformation linéaire des variables originales en composantes principales (CP) les moins corrélées entre elles (Jensen, 1996). En pratique, les trois premières CP renferment généralement plus de 95 % de l'information contenue dans les données initiales, si bien que les autres composantes sont souvent éliminées. L'intégration de ces trois premières composantes dans le MLP, plutôt que les variables originales permet de réduire la dimension de celui-ci. Cependant, les CP qui expliquent la plus grande variance ne possèdent pas nécessairement le plus grand pouvoir discriminant pour mettre l'accent sur les différences inter et intra classes. De ce point de vue, le choix systématique des premières composantes n'est pas toujours justifié.

L'ADS permet également de réduire le nombre de variables d'entrée d'un modèle en tenant compte des variances inter et intra groupe dont le rapport est maximisé. Cela a pour avantage d'optimiser la séparabilité entre les classes (Steiner, 1979). Cette méthode de sélection s'effectue par itérations successives. Lors de chaque itération, la contribution de chacune des variables indépendantes est évaluée par rapport à la variable dépendante et la statistique F est générée (Kleinbaum *et al.*, 1988). La variable originale ajoutée au modèle est celle dont la statistique F est la plus élevée. Avant de procéder à une nouvelle itération, les variables incluses dans le modèle sont analysées pour s'assurer qu'elles ne répondent pas au critère de sortie.

Dans le cadre de cette thèse, nous comparons ces deux méthodes de réduction des variables afin de déterminer celle qui donne les meilleurs résultats avec le réseau MLP sans grande perte d'informations. La méthode de réduction des données permet de déterminer également le nombre des neurones d'entrée du RN, alors que celui des neurones de sortie dépend du nombre de variables ou de classes à prédire. Mais il n'en est pas de même pour le nombre de neurones de la couche interne.

2.5.2 Neurones internes et validation croisée

Il n'existe pas de règles précises et définitives pour déterminer le nombre de neurones internes, car il est fonction de la complexité du problème à traiter (Batchelor *et al.*, 1997). Un trop grand nombre de neurones internes augmente la dimension du réseau, ce qui peut réduire ses performances, alors qu'un faible nombre ne permet pas de bien cerner le problème à traiter. Généralement, le nombre de neurones internes est compris entre le nombre de neurones d'entrée et de sortie. Une étude expérimentale est requise afin de déterminer ce nombre pour une configuration donnée du réseau. La plus part du temps, on détermine le nombre optimum en représentant graphiquement la performance du RN en fonction du nombre de neurones internes (Figure 2.4).

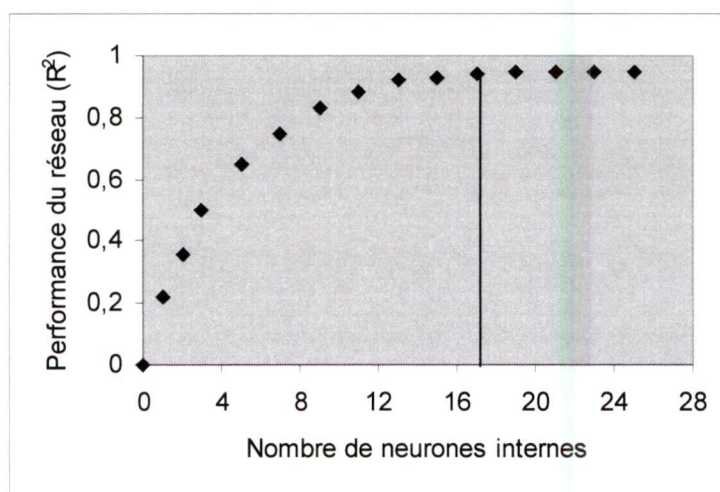


Figure 2.4 : Performance du RN selon le nombre de neurones internes

Le nombre de neurones optimum est celui à partir duquel la performance du réseau atteint un palier (la performance est représentée ici par le coefficient de régression entre les valeurs prédites et observées).

Pendant l'étape d'apprentissage, l'erreur quadratique diminue progressivement lorsque l'architecture du réseau est bien choisie. Mais plus cette erreur est faible, c'est-à-dire plus le réseau apprend à reconnaître la structure des données d'apprentissage, plus sa capacité de généralisation diminue (Bishop, 1995). On parle alors de sur-apprentissage, d'où l'importance de fixer un critère pour le contrôle de la phase d'apprentissage. C'est justement le rôle de la base de données de validation. Les variations simultanées des erreurs d'apprentissage et de validation sont décrites sur la figure 2.5. Le point à partir duquel l'erreur de validation commence à augmenter représente le début de la dégradation de la performance du RN. Ce processus de contrôle de la phase d'apprentissage est appelé validation croisée (Tarassenko, 1998). Une fois que le réseau est bien étalonné, il est appliqué sur une base de données indépendantes en vue de modéliser le phénomène étudié.




Figure 2.5 : Validation croisée durant l'apprentissage du réseau

2.6 Réseaux de neurones en agriculture

2.6.1 Extraction des variables agronomiques

De nombreux modèles physiques qui incorporent des données spectrales ont été développés pour extraire les variables agronomiques (Kimes *et al.*, 1998, Gong *et al.* 1999). Les limites de ces méthodes poussent les chercheurs à explorer d'autres techniques comme le RN afin d'extraire les variables de la végétation. Le RN peut modéliser convenablement un système quelconque à partir d'une bonne base de données. Il n'est pas nécessaire de connaître explicitement les relations existantes entre ces variables contrairement aux modèles physiques. Les cas d'utilisation du RN en général et du MLP en particulier, pour l'extraction directe des variables sont nombreux dans la littérature.

2.6.1.1 Extraction directe

L'extraction directe de variables agronomiques à l'aide du MLP basé sur des données spectrales est courante. Baret (1995) par exemple, a utilisé ce réseau pour déterminer avec succès le LAI et les teneurs en chlorophylle de la canne à sucre à partir des données SPOT et TM5. Ces résultats ont été comparés à ceux obtenus à partir des indices de végétation (IV) (NDVI¹, TSAVI² et MSAVI³). D'une manière générale, cette étude a fait ressortir la supériorité du MLP sur les IV. Ce réseau a prédit le LAI et les teneurs en chlorophylle avec des coefficients de régression de l'ordre de 0,92 à 0,94 pour 64 échantillons.

Des travaux similaires ont montré la capacité du MLP à modéliser correctement la relation entre les concentrations de chlorophylle de l'océan et des données simulées SeaWiFS (*Sea-viewing Wide Field of view Sensor*) (Keiner and Brown, 1999). La régression entre les concentrations de chlorophylle prédites et observées était de 0,96 et de 0,95 durant les phases d'apprentissage et de test du réseau respectivement. Ces auteurs

¹ Normalized difference vegetation index

² Transformed soil adjusted vegetation index

ont également montré que la performance de ce réseau augmente avec le nombre de neurones internes jusqu'à une valeur critique au-delà de laquelle les résultats se dégradent.

Une méthode d'extraction de la biomasse végétale basée sur le MLP a également été proposée par Jin et Liu (1997). Ces derniers ont intégré des données hyperfréquences passives et actives pour déterminer la hauteur, la teneur en eau et la fraction de matière sèche des plants de blé et d'avoine. Bien qu'ils soulignent la lenteur de convergence du MLP durant l'apprentissage, ils sont très satisfaits des résultats obtenus qui sont très proches des données de vérité terrain. Ils remarquent également que le réseau développé avec l'ensemble des données hyperfréquences passives et actives est meilleur que celui utilisant séparément ces mêmes données.

Les variables radiométriques ne sont pas les seuls paramètres de télédétection qui peuvent capter les informations relatives aux variables biophysiques de la végétation. En effet, des études ont démontré l'apport qualitatif des indices de texture à la discrimination des classes d'objets (Haralick, 1979; Skimodore *et al.*, 1997). Cependant, les exemples d'applications quantitatives de ces indices dans le domaine agricole sont quasi-inexistants dans la littérature. Le seul cas pertinent rencontré est celui de Murase *et al.* (1995) qui ont utilisé le MLP avec des images vidéos pour extraire l'humidité foliaire d'une culture de riz à partir de paramètres de texture. Bien que le faible nombre d'échantillons utilisés pose le problème de la représentativité des résultats obtenus, leurs travaux mettent en évidence l'utilité de la texture d'une image dans l'extraction d'informations quantitatives sur l'état physiologique des cultures.

Les exemples de prédiction des rendements agricoles à l'aide du MLP appliqué à des images aéroportées sont rares. On rencontre surtout des cas de prédiction des rendements à l'aide des RN basés sur des données de fertilité du sol et/ou des données climatiques (Uhrig *et al.*, 1992; Koch, 1994; Sudduth *et al.*, 1998). La plupart de ces modèles donnent certes de bons résultats, mais ils intègrent de nombreuses variables souvent difficiles à

³ Modified soil adjusted vegetation index

obtenir sur le terrain avec une bonne précision. De plus, un échantillonnage régulier de ces variables durant la saison agricole est fastidieux et très coûteux. Or, si l'on désire mettre en place un outil décisionnel pour aider les producteurs à faire des choix de gestion agricole, il faudrait que ce dernier fournisse des informations sur une base régulière pour mieux suivre l'évolution des cultures.

Les travaux de Simpson (1998) et de Shearer *et al.* (1998) ont particulièrement retenu mon attention, car ces auteurs ont prédit les rendements agricoles à l'aide d'images TM intégrées dans un RN. Simpson (1998) a utilisé un type de réseau peu commun dénommé CMAC (Cerebella model articulation controller) pour estimer les rendements du blé à partir du NDVI. Il a combiné cet indice avec des données de pluviométrie, de température, d'humidité du sol et de temps d'ensoleillement. Le CMAC a prédit les rendements du blé avec une erreur moyenne de 5 % et 8 % avec et sans le NDVI respectivement, soit une amélioration de 3 %. Mais l'auteur n'a effectué aucun test statistique pour déterminer si cette différence était significative ou non.

Shearer *et al.* (1998) ont plutôt intégré des bandes TM, des données de fertilité du sol et d'élévation dans un MLP pour prédire les rendements du maïs. Les différentes configurations qu'ils ont testées donnent une erreur RMS variant entre 1,09 kg/ha et 1,19 kg/ha. L'analyse des régressions entre les rendements prédits et observés montre cependant l'existence d'une grande dispersion des points. En fait, ces différents modèles de MLP, même ceux qui intègrent les données spectrales, surestiment les faibles rendements de maïs. Cela peut s'expliquer par le fait que leur base de données d'apprentissage n'était pas représentative du champ. En effet, il est recommandé d'utiliser un nombre d'échantillons égal ou plus élevé pour l'apprentissage (relativement aux échantillons de validation et de test) afin que le réseau apprenne mieux le pattern général de variation du phénomène modélisé (Tarassenko, 1998). Or, dans ce cas-ci, le MLP a été étalonné avec seulement soixante trois échantillons mesurés sur un transect diagonal, contre 117 échantillons prélevés sur une grille carrée couvrant tout le champ de maïs pour le test. Cet échantillonnage était donc très insuffisant pour extraire convenablement les structures spatiales présentes dans les données de rendements

agricoles. Pour contrer justement l'absence de données de terrain, on peut procéder de façon inverse en développant le RN sur des données spectrales simulées par un modèle de transfert radiatif.

2.6.1.2 Extraction par inversion de modèles physiques

Plusieurs algorithmes ont été développés en télédétection pour modéliser les propriétés optiques des surfaces végétales. Ils vont des simples modèles non linéaires à des modèles complexes de transfert radiatif (Kuusk, 1994; Fung, 1994). L'extraction des variables biophysiques de la végétation nécessite une inversion de ces modèles. Mais l'approche traditionnelle d'inversion qui consiste à utiliser des techniques d'optimisation numérique est longue et fastidieuse, à cause de la complexité de ces modèles (Kimes *et al.*, 1998). De plus, une solution optimale n'est pas toujours garantie. Pour remédier à cette situation, certains chercheurs utilisent une solution qui fait appel aux RN. Cette nouvelle approche d'inversion consiste à extraire les variables de la végétation à partir d'un RN développé sur des données simulées par un modèle physique de réflectance ou de rétrodiffusion. Le réseau ainsi étalonné est ensuite appliqué sur des données expérimentales (Wang and Dong, 1997; Satalino *et al.*, 1999).

Smith (1993) a utilisé cette approche pour générer une carte du LAI à partir du MLP entraîné sur des données simulées par le modèle de réflectance de Kubelka (Allen and Richardson, 1968). Ce réseau, testé ensuite sur une image TM, a donné de meilleures valeurs de LAI comparativement au modèle de régression multiple. Des travaux semblables ont été réalisés par Wang et Dong (1997) pour déterminer le diamètre moyen et la densité des arbres à l'aide du MLP. Les intrants de ce réseau étaient constitués par les coefficients de rétrodiffusion simulés. Une fois l'apprentissage terminé, le réseau a été testé de manière très satisfaisante sur des données mesurées au sol.

Quant à Pierce et Ulaby (1994) et Xianyun *et al.* (2000), ils ont inversé avec succès le modèle MIMICS à partir du MLP pour déterminer les paramètres de la végétation. Alors que Abuelgasim *et al.*, (1998) ont utilisé le même type de réseau pour inverser le modèle

d'optique géométrique de Li et Strahler (1992). Les cas d'extraction de l'humidité du sol à partir du modèle IEM (*Integral equation model*) inversé à l'aide du MLP sont également mentionnés par Satalino *et al.* (1999) et Del Frate *et al.*, (1999). Dans tous ces travaux, l'inversion des modèles physiques par le MLP s'est avérée très satisfaisante et surtout très prometteuse, malgré la grande simplicité de l'approche. Ces différents exemples d'applications démontrent encore une fois les grandes potentialités du MLP en milieu agricole où le suivi régulier de l'état de croissance des plantes est une exigence pour l'optimisation de la production finale.

2.6.2 Surveillance des conditions phénologiques des cultures

Les cas d'application au suivi des conditions de croissance des cultures sont nombreux dans la littérature (Thai and Shewfelt, 1991; Elizondo *et al.*, 1994). Toutefois, la prédiction du stress en azote à l'aide du RN en générale et du MLP en particulier, n'est pas spécifiquement traitée. Les applications courantes concernent surtout la détection de la présence des mauvaises herbes à l'intérieur d'un champ de maïs à l'aide d'indices de couleur extraits d'images numérisées (Yang *et al.*, 2000) ou encore la prédiction des périodes de floraisons et de maturité du soya à partir de données de températures journalières (Elizondo *et al.*, 1994). L'estimation des dégâts causés par des maladies à un champ de soya a été faite avec succès à partir de données biophysiques et de données climatiques (Batchelor *et al.*, 1997). Ruan *et al.* (1998) ont quant à eux combiné des IT avec des indices de couleurs pour prédire la proportion des dommages occasionnés par l'infestation de *Fusarium scab* dans un champ de blé.

Gopal et Woodcock (1996) ont combiné deux types de RN (MLP et ART - *Adaptive resonance theory*) pour détecter les effets d'une période prolongée de sécheresse sur des conifères à l'aide d'images TM. Il était question de déterminer le taux de mortalité des conifères, c'est-à-dire, de discriminer la proportion de conifères ayant subi un dommage de celle en "santé". C'est en fait une démarche de détection des changements utilisant un RN. Les résultats obtenus étaient de loin meilleurs à ceux de la méthode traditionnelle de détection de changement (Collins and Woodcock, 1995) utilisée à titre de comparaison.

Le pourcentage de bonne classification était de l'ordre de 59 % pour cette dernière contre environ 89 % pour les modèles neuronaux.

2.7 Conclusion

Ces nombreux cas d'application du MLP indiquent que ce dernier a été beaucoup utilisé pour résoudre divers problèmes en agriculture et en foresterie. Les études antérieures ont démontré son utilité dans la prédiction des variables biophysiques, ainsi que dans la discrimination des espèces végétales. Toutefois, peu d'auteurs abordent spécifiquement les cas de prédiction des rendements et du déficit en azote à partir d'images aéroportées et de la topographie. Les rares études qui s'y sont intéressées sont limitées par le nombre élevé d'intrants et les faibles résolutions spectrales et/ou spatiales des données de télédétection (Simpson, 1998); Shearer *et al.*, 1998). L'approche que nous proposons met l'accent non seulement sur le contenu en information des images à fines résolutions spatiales et spectrales, mais aussi sur la méthode de sélection des intrants du MLP.

Chapitre III

Méthodologie de recherche et traitements des données

3.1 Introduction

L'objectif de ce chapitre est de présenter la méthodologie adoptée pour cette recherche, de décrire et de traiter les données disponibles. Nous y exposons également la théorie de certaines méthodes de traitement, ainsi que les résultats obtenus.

3.2 Méthodologie de recherche

La méthodologie de recherche est basée sur l'intégration dans un MLP d'indices spectraux et texturaux issus d'images aéroportées et des paramètres topographiques, en vue de prédire les rendements du maïs et du soya, ainsi que le déficit en azote du maïs. Le potentiel des IV a largement été démontré en télédétection pour le suivi de la croissance des cultures et la prédiction des rendements. Toutefois, l'usage de l'information spectrale seule s'est avéré insuffisant, car différents objets peuvent avoir la même signature spectrale, d'où la difficulté de les discriminer convenablement (Peddle and Franklin, 1991).

Pour pallier ce problème, des données auxiliaires sont souvent utilisées pour améliorer la discrimination des objets spectralement identiques. Le premier type de données auxiliaires retenu pour notre étude concerne les paramètres de texture d'Haralick (Haralick, 1979). Ceux-ci renseignent sur l'organisation spatiale des pixels d'une image et peuvent être très utiles pour caractériser quantitativement le rendement agricole et faciliter l'identification des parcelles de maïs fertilisées avec différents taux d'azote.

Bien que des sols couverts de végétation soient très peu visibles par télédétection, il est bien connu que la croissance végétale est contrôlée par la distribution spatio-temporelle des propriétés physico-chimiques des sols (Cassel *et al.*, 2000). Par conséquent, l'intégration des effets de ces différentes propriétés influence le patron de production de la biomasse végétale et donc le rendement agricole. En effet, la disponibilité en éléments nutritifs du sol, le drainage et la structure de ce sol sont généralement liés à la topographie du champ (Kravchenko and Bullock., 2000). De plus, selon l'orientation des pentes par rapport au soleil, la culture peut recevoir ou non plus de lumière, ce qui influence son métabolisme interne. Par conséquent, nous avons choisi les paramètres topographiques comme seconde donnée auxiliaire plutôt que les éléments de fertilité du sol.

La démarche scientifique globale du projet de recherche comprend les étapes suivantes (Figure 3.1) :

- Étape 1 :** Collecte, traitements préliminaires et analyses des données physico-chimiques du sol, des rendements et des images de télédétection;
- Étape 2 :** Calcul des indices spectraux et texturaux à partir des images aéroportées, et interpolation des données terrain pour générer les cartes d'élévation, des pentes, de l'orientation des pentes et des rendements agricoles;
- Étape 3 :** Intégration des couches d'informations précédentes dans le logiciel ArcView (ESRI, 1995a) pour l'extraction aléatoire des pixels échantillons;

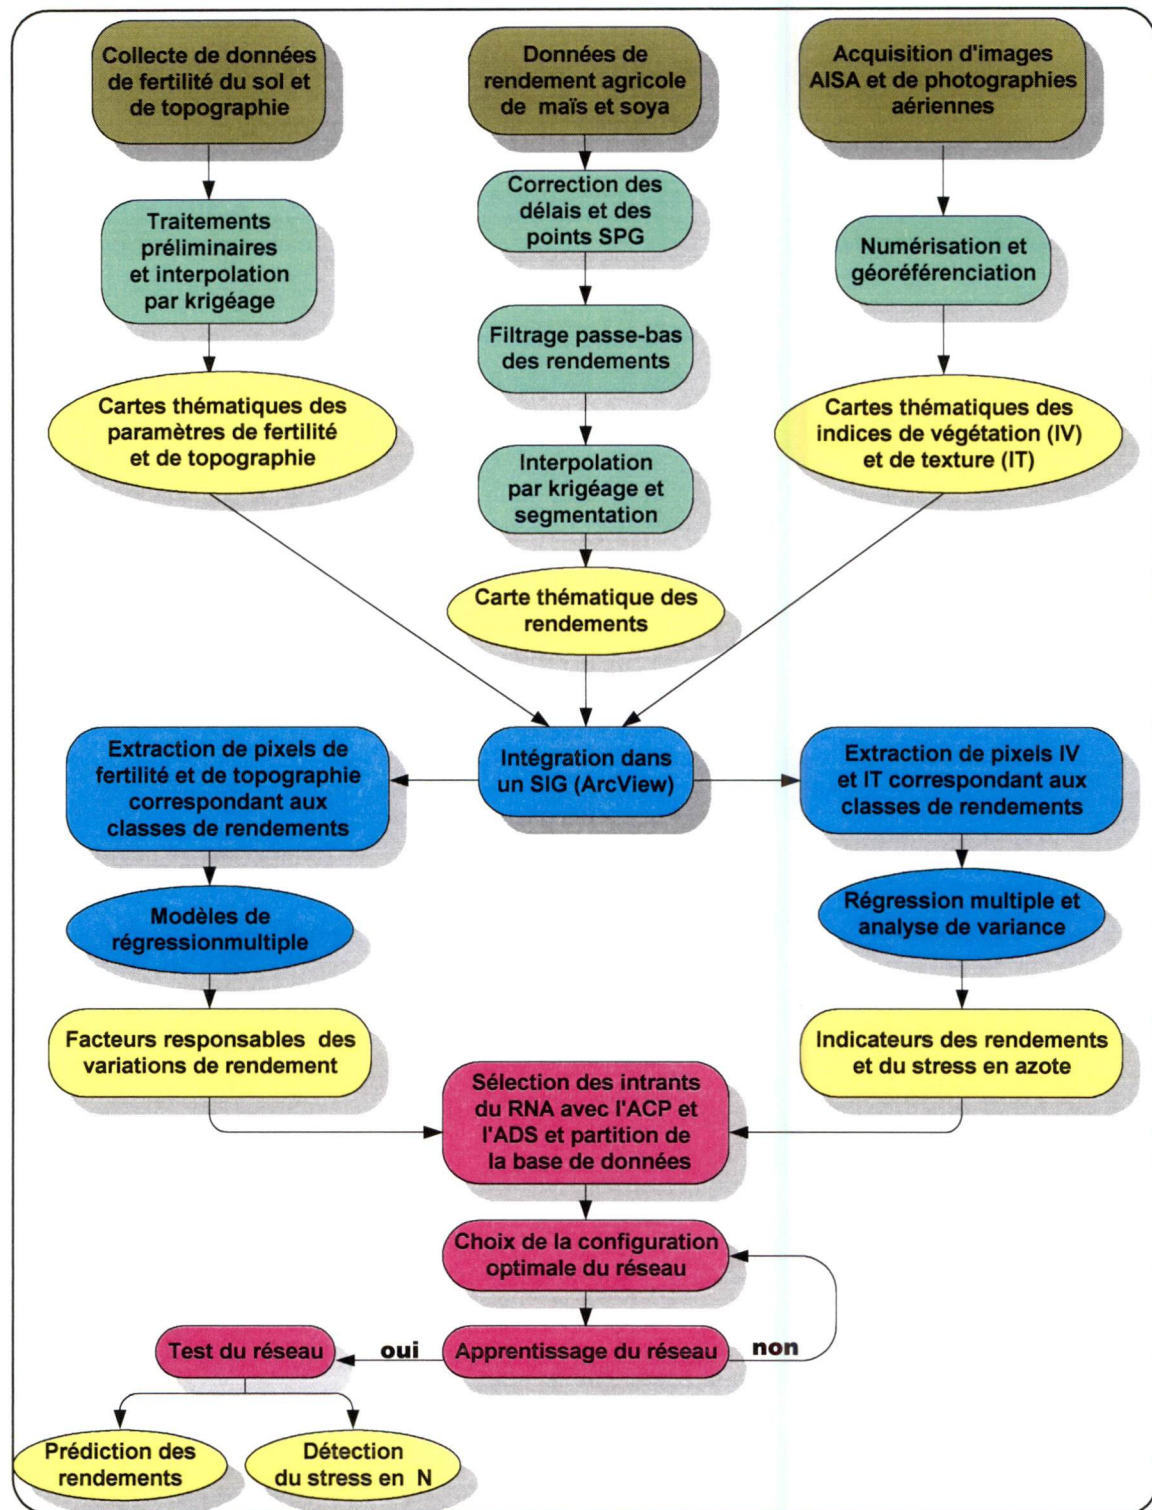


Figure 3.1 : Schéma conceptuel du projet de recherche

- Étape 4 :** Identification des facteurs responsables de la variabilité spatiale des rendements du maïs et du soya à l'aide de l'analyse multivariée entre ces rendements et les paramètres de fertilité du sol et de topographie;
- Étape 5 :** Évaluation de la capacité des images aéroportées à identifier les variations spatiales des rendements du maïs et du soya et du stress en azote du maïs;
- Étape 6 :** Sélection des intrants du MLP à l'aide de l'ACP et l'ADS et partition de la base de données en trois groupes : la base d'apprentissage qui sert à étalonner le MLP par la définition des poids des neurones, la base de validation dont le but est de contrôler et d'arrêter l'apprentissage et la base de test qui est destinée à évaluer les capacités de généralisation du MLP.
- Étape 7 :** Développement et test du MLP à partir d'une base de données constituée de 600 à 750 pixels extraits des couches d'informations de IV, IT, des paramètres topographiques et des rendements du maïs et du soya.

3.3 Sites d'études et description des données

3.3.1 Sites d'études

Les données utilisées proviennent de deux sites. Le premier site d'une superficie de 30 hectares est situé à la ferme expérimentale d'Agriculture et agroalimentaire Canada (AAC) à Ottawa (ON). C'est un site relativement bien drainé. Le sol y est dominé par des argiles terreuses sur une profondeur d'environ 30 cm et du maïs y a été cultivé en mai 1998. Le second site d'étude est localisé dans la région de St-Jean-sur-Richelieu (Montréal, QC) sur un sol minéral également caractérisé par une faible topographie. Il s'agit du champ Lamoureux-Pinsonneault sud cultivé en soya durant le mois de mai 1997 sur une superficie de 9 hectares.

3.3.2 Données de télédétection

Le capteur AISA (*Airborne imaging spectrometer applications*) a été utilisé pour l'acquisition d'images au-dessus maïs. Il est munie de 288 bandes ayant une résolution spectrale qui varie de 1,63 à 9,8 nm (Makisara *et al.*, 1993). Pendant que ce capteur enregistre l'intensité lumineuse réfléchie par la surface, un autre capteur disposé sur le toit de l'avion mesure à la même fréquence l'intensité du rayonnement solaire incident. Le rapport de ces deux mesures permet de déterminer la réflectance de la surface. Trois images ont ainsi été prises à une altitude de 1500 m et une résolution spatiale de 1,5 m. Les dates d'acquisition furent le 8 juin (10 bandes spectrales), le 21 juillet (14 bandes) et le 13 septembre 1998 (18 bandes). Ces images couvrent des longueurs d'onde entre 430 nm et 900 nm avec une résolution spectrale de 2 nm à 8 nm.

Le champ de soya a été couvert par une série de photographies infrarouges couleurs acquises durant l'été 1997 à l'aide d'une caméra Kodak (Michel Brouillard – 2000 – communication personnelle). Celles-ci ont été prises le 11 juin, 5 juillet, 30 juillet, 5 septembre et 4 octobre à une altitude d'environ 1500 m, avec une taille de pixel au sol de 0,95 m. Ces photographies n'ont pas été étalonnées radiométriquement pour des raisons de logistique et de coût. Les niveaux de gris ont donc été considérés pour le soya.

3.3.3 Données de rendement agricole

Les semis ont débuté le 16 mai 1998 et le 27 mai 1997 pour le maïs et le soya respectivement. Les récoltes ont eu lieu entre le 13 et le 23 octobre. L'espacement entre les rangs était de 75 cm pour le maïs et de 40 cm pour le soya. Le rendement final de ces cultures a été enregistré à l'aide d'une moissonneuse-batteuse équipée d'un capteur de rendements de type AGLEADER-2000 (maïs) et RDS (*Rural development system*) (soya). Les largeurs de coupe de ces moissonneuses étaient de 3 m pour le maïs et 7,5 m pour le soya. Ces systèmes comprenaient un capteur de rendement proprement dit, un capteur de vitesse, un capteur d'humidité des grains et un SPG. Les valeurs de rendement

obtenues pour chaque champ ont été introduits dans le SIG ArcView pour traitement et interpolation par krigeage.

3.3.4 Données physico-chimiques du sol

Les données physico-chimiques du sol des deux sites d'études font référence aux éléments de fertilité et à l'élévation. Les échantillons ont été collectés à 30 cm de profondeur sur une grille de 100 x 100 m dans le champ de maïs (Figure 3.2). Sur le site du soya, ces échantillons de sol ont été pris à 15 cm de profondeur sur une grille de 20x20 m (Figure 3.3). Les éléments de fertilité du sol comprenaient : la matière organique (MO), le phosphore (P), le potassium (K), le magnésium (Mg), le calcium (Ca), le pH et la capacité d'échange cationique (CEC).

Les données d'élévation ont été prises par un transmetteur laser et un SPG installés sur un véhicule qui a couvert l'ensemble des sites. Les points d'échantillonnage étaient distants d'environ 20 m et la résolution spatiale des données était de l'ordre de 2 m. Toutes ces données ont également été intégrées dans ArcView pour générer des cartes.

3.3.5 Cas des parcelles fertilisées en azote

Dans le but d'induire des conditions de déficit azoté et d'avoir des plant de maïs à différents stades de croissance, trois parcelles ont reçu des quantités distinctes d'azote (Figure 3.4). La première (2,6 ha) a été fertilisée avec 10 % de la dose d'azote recommandée (155 kg N ha^{-1}), la seconde (3,7 ha) avec 64 % d'azote, la zone de référence (23,7 ha) a reçu 100 % de la dose normale (Pattey *et al.*, 2001). Quant aux P et K, ils ont été appliqués uniformément dans tout le champ de maïs à des taux respectifs de 45 kg P ha^{-1} et 30 kg K ha^{-1} .




Figure 3.2 : Grille d'échantillonnage du sol dans le champ de maïs




Figure 3.3 : Grille d'échantillonnage du sol dans le champ de soya




Figure 3.4 : Parcelles de maïs fertilisées avec différentes doses d'azote

Un échantillonnage « destructif » du LAI a été effectué de manière aléatoire en prenant 15 à 20 plants par parcelle une fois par semaine dans la grille 50 x 50 m (Figure 3.4). La réflectance du maïs a été mesurée également durant la saison à l'aide d'un spectroradiomètre de type GER¹-1500 (300 nm à 1100 nm) ayant une résolution spectrale de 3 nm. Le champ optique de ce dernier était de 23° pour une hauteur d'environ 40 cm au-dessus des plants de maïs. Pour chaque point considéré, cinq mesures de réflectance ont été prises et moyennées. Ces mesures ont été acquises autour du midi solaire entre le 1^{er} juin et le 16 septembre au moment de la collecte des données de LAI. L'étalonnage du GER en réflectance a été effectué en visant un panneau de référence (spectralon de 30 x 30 cm) au début et à la fin de chaque expérience. La réflectance du sol a été mesurée en début de saison pour déterminer la droite des sols nus.

¹ *Geophysical and environmental research*

3.4 Traitements et analyses des données

3.4.1 Images AISA et photographies aériennes

Les images AISA et les photographies infrarouges couleurs ont été fournies par AAC. Elles ont été géoréférencées dans les systèmes UTM² pour les images AISA et MTM³ pour les photographies aériennes. Ces photographies ont ensuite été numérisées par balayage optique à 400 dpi (*dot per inch*) pour générer des images ayant des pixels de 1 mètre au sol. Toutes ces images ont ensuite été rééchantillonnées à la même résolution spatiale que la carte des rendements du maïs (AISA) et du soya (photographies aériennes) à l'aide de la méthode du plus proche voisin. Celle-ci est couramment utilisée en télédétection, car c'est une méthode très efficace qui n'altère pas les niveaux de gris de l'image originale (Lillesand and Kiefer, 2000).

Les courbes de variations de la biomasse végétale ont été essentielles dans le choix des images pertinentes à notre recherche (Figures 3.5 et 3.6). Ces courbes ont permis de localiser facilement les périodes de croissance où le développement des cultures est à son maximum. On remarque ainsi, que le maïs et le soya croissent très rapidement jusqu'à un maximum situé autour du 10 août avant de décroître progressivement durant la phase de sénescence. Ces deux phases sont séparées par une phase de phase de plateau qui est peu perceptible sur nos données à cause du nombre de points restreints.

Selon nos données, la maturité physiologique maximale du maïs a eu lieu autour du 10 août 1998 (Figures 3.5) avec une phase d'activité biologique maximale située approximativement entre le 20 juillet et le 30 août. Nous disposons donc d'une seule image AISA acquise durant la phase de croissance optimale du maïs, précisément le 21 juillet avec un LAI de 3,75. Quant à l'image du 13 septembre, elle se situe au début de la sénescence et le LAI correspondant est de l'ordre de 2,5. Contrairement aux images de juillet et de septembre, celle de juin (LAI = 0,6) témoigne d'une très faible croissance du maïs, si bien qu'elle n'a pas été retenue dans la suite de nos travaux.

² *Universal transversal mercator*

³ *Mercator transverse modifiée*




Figure 3.5 : Variations du LAI dans le champ de maïs (★= dates images)




Figure 3.6 : Variations temporelles du NDVI dans le champ de soya

La variation du NDVI de la figure 3.6 montre que la maturité du soya était maximale au 5 août 1997, soit une période maximale de croissance s'étalant du 20 juillet au 25 août. Nous remarquons donc que l'image du 11 juin (NDVI = 0,1) a été acquise en condition de sol presque nu, alors que celle du 4 octobre a été prise sur des plantes de soya très sénescentes (NDVI = 0,07). Par conséquent, ces deux images étaient moins pertinentes pour la prédiction des rendements du soya. Comme pour le maïs, il n'y avait qu'une seule image qui était localisée dans la phase de développement maximum du soya. Il s'agit de celle prise le 30 juillet. Toutefois, les images des 5 juillet et 5 septembre ont été retenues pour comparaison.

Pour mettre en évidence l'activité chlorophyllienne du maïs et du soya, nous avons utilisé les IV qui sont une combinaison des réflectances des bandes spectrales. Parmi les longueurs d'ondes du spectre électromagnétique, le proche infrarouge (PIR) est le plus corrélé au taux de couverture végétale et au LAI. Cependant, il est aussi influencé par des facteurs tels que l'humidité du sol, le type de sol, les conditions d'illumination, l'architecture de la plante et la couleur des feuilles (Clevers, 1988). Pour atténuer les effets de ces facteurs, des IV sont calculés à partir des réflectances du PIR et des bandes du visible. Nous avons retenu quatre IV parmi les plus utilisés en télédétection :

- Le NDVI est probablement l'indice le plus utilisé pour le suivi du couvert végétal, bien que sensible à la géométrie de l'éclairement et de visée pour les faibles végétations (Holben and Fraser, 1984). Sa formule générale est la suivante :

$$NDVI = \frac{PIR - R}{PIR + R} \quad (3.1)$$

où R est la réflectance de la végétation dans le canal rouge.

- Le SAVI (*Soil adjusted vegetation index*) est une amélioration du NDVI qui utilise un paramètre d'ajustement permettant de réduire l'effet du sol (Huete and Jackson, 1988). Il est défini par l'équation (3.2) :

$$SAVI = \frac{(PIR - R)}{PIR + R + L} (1 + L) \quad (3.2)$$

où L est le facteur d'ajustement indépendant du type de sol ou du capteur.

Les travaux de Bausch (1993) ont permis d'établir une relation entre ce facteur et le LAI. Ainsi, $L = 0,6$ pour des valeurs de $LAI \leq 1$, $L = 0,4$ pour $1 < LAI \leq 2,5$ et $L = 0,15$ pour $LAI > 2,5$.

- Le TSARVI (*Transformed soil and atmospherically resistant vegetation index*) exploite les canaux bleu et rouge au lieu du canal rouge uniquement pour réduire les effets atmosphériques (Bannari *et al.*, 1998). Sa formule générale s'écrit :

$$TSARVI = \frac{[a_{rb}(PIR - a_{rb}RB - b_{rb})]}{[(RB + a_{rb}PIR - a_{rb}b_{rb} + 0,08*(1 + a_{rb}^2))]} \quad (3.3)$$

avec

$$RB = R - \gamma * (B - R) \quad (3.4)$$

où B est la réflectance dans le canal bleu, a_{rb} et b_{rb} sont les coefficients de la droite des sols nus dans l'espace bleu-rouge et γ est un facteur d'autocorrélation atmosphérique qui dépend du type d'aérosol.

- Le WDV est très fiable pour l'estimation du LAI et du taux de couverture végétale (Bouman *et al.*, 1992). L'avantage de cet indice est qu'il effectue des corrections par rapport aux effets d'humidité du sol pour de faibles couverts végétaux. Sa formulation générale est la suivante :

$$WDVI = PIR_v - VIS_v \left(\frac{PIR_s}{VIS_s} \right) \quad (3.5)$$

où VIS est la réflectance dans le visible; V et S font respectivement référence à la végétation et au sol nu.

La création d'images de texture est basée sur la méthode de co-occurrence développée par Haralick et Shanmugan (1973) en vue de quantifier les différentes caractéristiques de la texture d'une image. Il s'agit d'une approche statistique qui exprime dans une matrice, la probabilité d'occurrence d'une paire de pixels i et j séparés par une distance d'influence d pour une orientation et une taille de fenêtre spécifique. Quatorze indices de textures sont extraits de cette matrice pour l'interprétation d'une image. Mais l'utilisation courante de ces paramètres en agriculture se limite généralement au second moment angulaire (SMA), au contraste (CON), à l'entropie (ENT) et à l'homogénéité (HOM).

Le SMA mesure l'uniformité texturale d'une image, c'est-à-dire, la répétition d'une paire de pixels. Il atteint son maximum lorsque la distribution des niveaux de gris de l'image est constante dans la fenêtre mobile. Quant au CON, il fait ressortir les zones hétérogènes de l'image. Sa valeur est plus élevée pour une image qui présente de fortes variations locales. L'ENT mesure le degré de désordre d'une image. Lorsque celle-ci ne présente pas d'uniformité texturale, l'entropie est très élevée. L'HOM mesure l'homogénéité d'une image, laquelle est traduite par de faibles transitions des niveaux de gris.

3.4.2 Algorithme de correction des rendements agricoles

La carte de rendements constitue une source considérable d'information et elle occupe une place importante dans le processus de gestion agricole (Birrell and Sudduth, 1996). Elle montre la variabilité spatiale et temporelle des rendements à travers le champ. On peut ainsi différencier les zones de faible productivité, de celles de forte productivité, ce qui permet d'évaluer les stratégies de gestion agricole. Cependant, son usage courant est limité par les nombreuses erreurs inhérentes aux données des capteurs de rendement, si bien que les variations spatiales observées sur cette carte ne reflètent pas toujours la réalité du champ (Thylén *et al.*, 1996; Murphy *et al.*, 1995). Par conséquent, une série de traitements est nécessaire pour minimiser les effets de ces erreurs. Ces traitements portent généralement sur la correction des délais, du filtrage des hautes fréquences, de la déviation des points du SPG, du taux d'humidité des grains, des valeurs extrêmes

associées aux variations de vitesse de la moissonneuse et des points enregistrés en double (Lamb *et al.*, 1995; Blackmore and Marshall, 1996).

Plusieurs travaux ont été réalisés pour quantifier les effets des erreurs présentes dans les données de rendements (Stafford *et al.*, 1996). Ces recherches ont certes abouti à des protocoles de corrections de ces données, mais peu d'auteurs proposent des algorithmes qui prennent en compte la majorité des perturbations induites par les capteurs de rendements. L'algorithme proposé par Blackmore et Marshall (1996), permet de compenser les erreurs associées uniquement à la largeur de coupe de la moissonneuse. Quant à Han *et al.* (1996), ils ont développé une méthode basée sur ce même principe, mais avec une structure beaucoup plus complexe. Rands (1995) a concentré ses efforts sur un « filtre expert » qui élimine les valeurs de rendements erronés à partir d'une base de données contenant des informations sur le site, le capteur, le SPG et la culture. D'autres auteurs comme Birrell et Sudduth (1996) ont plutôt investigué des modèles mathématiques pour modéliser et reconstruire le signal issu des capteurs de rendements.

Bien que toutes ces méthodes produisent généralement de bons résultats, elles sont spécifiques à une problématique donnée et donc moins pertinentes pour un utilisateur qui manipule couramment les données de rendements agricoles. Pour pallier ce manque, nous avons développé un algorithme en langage *C* afin d'automatiser la correction de la majorité des erreurs contenues dans les données de rendements. Ce dernier a été appliqué aux rendements du maïs, car ceux du soya étaient partiellement corrigés par AAC. Seul le filtrage y a donc été effectué. Cet algorithme baptisé DEFIS dispose de trois modules de correction dénommés **DÉLAI**, **FILTRAGE** et **SPG** (Figure 3.7).

3.4.2.1 Module DÉLAI

Ce module permet de corriger les délais avant et arrière présents dans les rendements agricoles. Ces délais représentent le temps qui s'est écoulé entre le moment de la coupe des grains et leur enregistrement au capteur (délai avant) et entre l'arrivée au bout de la ligne de battage et l'instant où la table de coupe est soulevée (délai arrière).

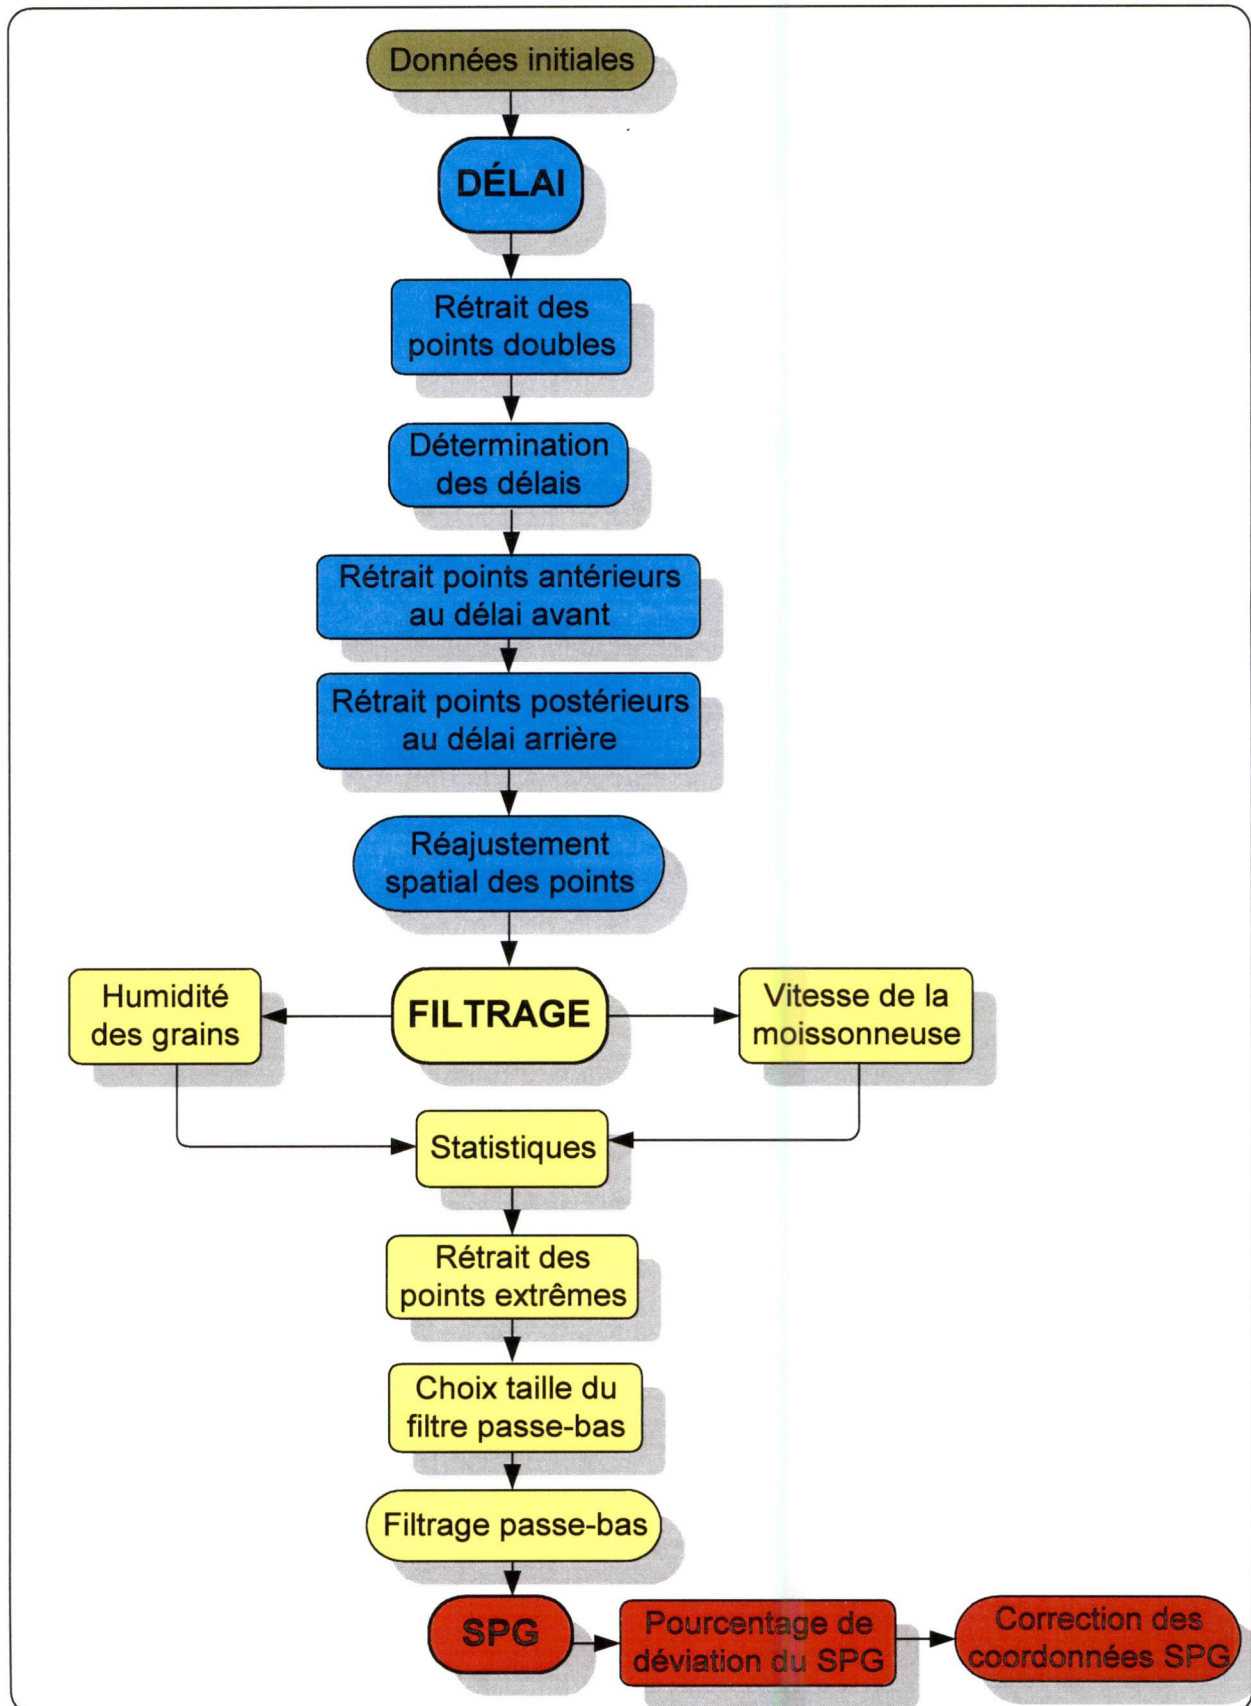


Figure 3.7 : Organigramme de l'algorithme de correction des rendements agricoles

La conséquence des délais est d'introduire des points erronés et de créer un déphasage spatial entre les coordonnées géographiques et les rendements enregistrés (Lamb *et al.*, 1995). Pour corriger leurs effets sur les rendements, l'utilisateur doit d'abord déterminer graphiquement les durées correspondantes selon la procédure suivante :

1. Représenter graphiquement la variation des rendements en fonction des 50 à 60 premières (délai avant) et dernières (délai arrière) secondes pour une dizaine de parcours de la moissonneuse;
2. Faire la moyenne des courbes de variation des rendements et y ajuster une fonction polynomiale;
3. Déterminer :
 - a. La durée entre les rendements nuls et le point à partir duquel la variation de ces rendements commence à se stabiliser (délai avant);
 - b. La durée entre le moment où la variation des rendements commence à diminuer progressivement et le point où elle s'annule (délai arrière);

Les délais ainsi déterminés sont alors introduits dans le module DÉLAI qui :

4. Élimine tous les points antérieurs au délai avant et postérieurs au délai arrière pour chaque parcours considéré. Le nombre de points éliminés est équivalent à la valeur du délai en seconde pour chaque cas, si les rendements sont enregistrés à intervalle d'une seconde;
5. Réajuste ensuite toutes les valeurs de rendements afin de corriger le décalage spatial des points, car les rendements enregistrés par le capteur ont été récoltés plusieurs mètres derrière la moissonneuse en déplacement.

Les figures 3.8 et 3.9 montrent la détermination graphique des délais dans le cas du maïs. Ils sont de l'ordre de 22 et 20 secondes pour les délais avant et arrière respectivement. Les valeurs rapportées pour le soya sont respectivement de 23 et 23 secondes (Michel Brouillard, 2000 – communication personnelle). Le pourcentage global des points éliminés après correction de ces délais était de 10 % du nombre total des rendements du maïs mesurés par le capteur. Ces délais sont en accord avec ceux couramment cités dans la littérature et qui se situent entre 15 et 40 secondes pour le délai avant et 10 à 20 secondes pour le délai arrière (Murphy *et al.*, 1995; Thylén *et al.*, 1996).

Le module DÉLAI est également muni d'un sous programme qui lui permet de déterminer automatiquement les délais avant et arrière. Contrairement à la méthode graphique qui estime une valeur moyenne pour tout le champ, ce sous programme détermine les délais spécifiques à chaque trajet de la moissonneuse. Cela évite une généralisation qui pourrait entraîner une suppression d'une partie des structures spatiales présente dans les rendements agricoles.

Pour un trajet donné, ce sous programme fonctionne comme un « filtre » qui accepte une valeur ponctuelle des rendements si la condition fixée est remplie. Ce filtre a été adapté de la forme originale proposée par Moore (1997). Nous considérons donc le délai avant comme équivalent au temps t pour lequel la valeur du rendement mesuré au début du trajet est égale à 95 % de la moyenne des cinq prochaines valeurs de rendement :

$$R_{av} = \left[\frac{(R_{i+1} + R_{i+2} + R_{i+3} + R_{i+4} + R_{i+5})}{5} \right] * 0,95 \quad (3.6)$$

où R_{av} est le rendement seuil pour le délai avant, R_i représentent les rendements mesurés à l'avant du trajet.

Pour i égale à 1 par exemple, les rendements R_1 et R_{av} sont comparés entre eux. Les rendements mesurés par le capteur sont considérés comme non valides jusqu'à ce que R_1 soit supérieure ou égale à R_{av} .




Figure 3.8 : Détermination du délai avant (d.av.) des rendements du maïs




Figure 3.9 : Détermination du délai arrière (d.ar.) des rendements du maïs

Dans le cas du délai arrière, l'approche est similaire, sauf qu'on cherche le point pour lequel la valeur du rendement mesuré dans la partie finale du trajet est égale à 95 % de la moyenne des cinq valeurs antérieures :

$$R_{ar} = \left[\frac{(R_{j-1} + R_{j-2} + R_{j-3} + R_{j-4} + R_{j-5})}{5} \right] * 0,95 \quad (3.7)$$

où R_{ar} est le rendement seuil pour le délai arrière, R_j représentent les rendements mesurés vers la fin du trajet.

Pour j égale à 6 par exemple, les rendements R_6 et R_{ar} sont comparés entre eux. Les rendements mesurés par le capteur sont considérés comme non valides jusqu'à ce que R_6 soit supérieure ou égale à R_{ar} .

L'application de ce filtre aux rendements du maïs a généré des résultats plus faibles comparativement à la méthode graphique. Les délais moyens des données étaient respectivement de 11 ($\pm 1,8$) et 9 ($\pm 1,9$) secondes au début et à la fin du trajet de la moissonneuse. Cela correspond à environ 5 % de points erronés éliminés sur l'ensemble du champ, contre 10 % par la méthode graphique. Cette diminution des délais est conforme aux figures 3.8 et 3.9 qui montrent que ces derniers variaient énormément d'un trajet à un autre et que considérer des valeurs moyennes pour tout le champ peut induire des erreurs importantes dans l'interprétation de la variabilité spatiale des rendements.

Les délais déterminés par cette deuxième méthode étaient également très voisins de ceux rencontrés dans la littérature (Murphy *et al.*, 1995; Thylén *et al.*, 1996). C'est donc le fichier corrigé par cette dernière méthode qui a été transféré au module FILTRAGE pour la réduction des hautes fréquences.

3.4.2.2 Module FILTRAGE

Le module de filtrage a pour but de réduire les fréquences induites par les vibrations de la moissonneuse. Celles-ci sont caractérisées par des fréquences plus élevées que celles provoquées par les variations du flux massique des grains. La composante du signal induite par les hautes fréquences peut être éliminée à l'aide d'un filtre passe-bas qui remplace chaque valeur de rendement par une moyenne pondérée sur plusieurs points (Vansichen and De Baerdemaeker, 1991). L'estimation des rendements par unité de surface est meilleure après application, car issue de plus d'une valeur. Lors de cette pondération, les poids les plus faibles sont attribués aux points les plus éloignés du centre de la fenêtre mobile, c'est-à-dire du point à filtrer (Wayne, 1986).

La forme générale du filtre de la moyenne pondérée utilisé dans le cadre de cette recherche est représentée par l'équation (3.8) pour cinq points :

$$Y_j = C_2 X_{j-2} + C_1 X_{j-1} + C_0 X_j + C_1 X_{j+1} + C_2 X_{j+2} \quad (3.8)$$

avec

$$C_i = \frac{m-i}{m^2} \quad (3.9)$$

et

$$m = 0,5(t-1) + 1 \quad (3.10)$$

Où t est la taille du filtre (nombre impair), i et $j = 0$ à $m-1$, X et Y sont respectivement les rendements bruts et filtrés.

Les tableaux 3.1 et 3.2 et les figures 3.10 et 3.11 résument les résultats de l'application du filtre de la moyenne pondérée aux rendements pour un parcours de la moissonneuse. La moyenne des rendements filtrés varie de 5,34 kg/ha à 5,48 kg/ha pour le maïs et de 3,83 kg/ha à 3,89 kg/ha pour le soya. Cette augmentation de la moyenne s'explique par le fait que les filtres de grande taille accentuent la réduction des valeurs extrêmes des données. Nous remarquons également que plus la taille du filtre augmente plus le coefficient de

variation (CV) diminue, ce qui traduit une homogénéisation de la variance des rendements agricoles. On passe ainsi des coefficients respectifs de 17 % et 10 % pour les rendements bruts de maïs et soya, à des coefficients de 14 % et 7 % pour les rendements de filtrés. Toutefois, pour la suite du travail, nous avons sélectionné le filtre F 9 plutôt que le F 11 pour le traitement final des rendements. En effet, la valeur absolue du kurtose des données de maïs et de soya est plus faible pour le filtre à 9 points que celui à 11 points, ce qui signifie que la distribution des rendements traités par le F 9 se rapproche beaucoup plus d'une distribution normale. De plus, l'effet de bord occasionné par la procédure de filtrage est moins accentué avec un filtre de petite taille. Il est donc plus avantageux d'opter pour une taille de filtre plus petite tout en restant optimale par rapport au contenu en information. Il faut enfin mentionner que ce module donne la possibilité à l'utilisateur de choisir entre les filtres de la moyenne pondérée et de la moyenne simple, ainsi que la taille du filtre.

Tableau 3.1: Filtrage des rendements du maïs pour un parcours

Statistiques	Brut	⁴ F 5	F 7	F 9	F 11
Moyenne (t/ha)	5,34	5,41	5,44	5,46	5,48
Écart type(t/ha)	0,88	0,81	0,79	0,76	0,76
Minimum (t/ha)	1,29	1,63	2,70	3,11	3,37
Maximum (t/ha)	8,33	8,16	7,82	7,64	7,51
CV (%)	17	15	15	14	14
Kurtose ⁸	2,85	1,96	0,70	0,05	-0,29

n = 450

Tableau 3.2: Filtrage des rendements du soya pour un parcours

Statistiques	Brut	F 5	F 7	F 9	F 11
Moyenne (t/ha)	3,83	3,88	3,88	3,89	3,89
Écart type(t/ha)	0,39	0,30	0,28	0,27	0,27
Minimum (t/ha)	0,73	1,71	2,08	2,25	2,32
Maximum (t/ha)	4,62	4,36	4,35	4,32	4,30
CV (%)	10	8	7	7	7
Kurtose	8,55	6,30	5,13	4,90	5,07

n = 420

⁴ Filtre : de fenêtre 5 x 5, 7 x 7, 9 x 9 et 11 x 11

⁸ La mesure du kurtose caractérise l'aplatissement relatif de la distribution d'une variable donnée par rapport à une distribution gaussienne (kurtose = 0) (Hair *et al.*, 1998)




Figure 3.10 : Filtrage des rendements du maïs pour un parcours




Figure 3.11 : Filtrage des rendements du soya pour un parcours

3.4.2.3 Module SPG

Bien que les modules DÉLAI et FILTRAGE aient contribué à réduire une partie des erreurs des données de rendements, ils ne corrigent pas les distorsions des points du SPG. Cette tâche est effectuée par le module SPG qui utilise la théorie des moindres carrés pour ajuster ces points (Baillargeon, 1984). Cette théorie a permis de trouver la droite qui s'ajuste le mieux au nuage des points du SPG tout en minimisant la somme des carrés des écarts entre les points estimés et ceux mesurés. La correction a ainsi consisté à déterminer d'abord l'équation de la droite théorique passant par le maximum de points du trajet de la moissonneuse, puis à recalculer les coordonnées correspondantes à chaque valeur ponctuelle. Cette droite théorique est représentée par l'équation (3.11) :

$$Y'_i = a + b * X_i \quad (3.11)$$

avec

$$b = \frac{n \sum X_i Y_i - (\sum X_i)(\sum Y_i)}{n \sum X_i^2 - (\sum X_i)^2} \quad (3.12)$$

et

$$a = Y_m - b * X_m \quad (3.13)$$

où Y'_i représente les coordonnées réajustées, Y_i et X_i sont les coordonnées mesurées par le SPG, a et b sont des constantes, n est le nombre total de points, Y_m et X_m représentent les moyennes respectives des Y_i et X_i .

Le coefficient de régression R^2 de la droite théorique est déterminé par l'équation (3.14) :

$$R^2 = \frac{\sum (Y'_i - Y_m)^2}{\sum (Y_i - Y_m)^2} \quad (3.14)$$

Si le parcours de la moissonneuse ne présente aucune distorsion, le coefficient R^2 est égal ou très proche de 1, sinon les coordonnées originales sont remplacées par de nouvelles coordonnées interpolées. La figure 3.12 est un exemple de distorsions du SPG. Parmi les données dont nous disposons, seuls les rendements du maïs présentaient une déviation latérale des points SPG par rapport à l'axe principal de la moissonneuse. Des 160 trajets que comptaient les données, seulement 63 possèdent des coefficients R^2 inférieurs à 0,99, soit 39 %. Nous avons remarqué que l'amplitude des déformations était faible et très localisée. Elle s'étendait latéralement sur 5 à 7 m en moyenne. Par conséquent, si l'interpolation des données de rendements est effectuée dans une grille dont la résolution spatiale est plus grande que 7 m, les effets de ces déviations latérales sur les rendements du maïs seront négligeables.




Figure 3.12 : Déviations des points du SPG pour un parcours

3.4.3 Analyse géostatistique

3.4.3.1 Semivariogrammes des rendements

L'étude de la variabilité spatiale d'une variable requiert l'utilisation de méthodes géostatistiques tels que le semivariogramme, car les statistiques classiques ne permettent pas d'expliquer adéquatement l'existence de structures spatiales (Toner *et al.*, 1997). Le semivariogramme est défini comme une fonction qui quantifie la dépendance spatiale entre deux échantillons séparés par une distance h . En fait, il décrit la relation entre semivariance et la distance en calculant la moyenne de l'écart quadratique entre deux points. Il est déterminé par l'expression de l'équation (3.15) :

$$2\gamma(h) = \frac{1}{H} \sum_{i=1}^H (x_i - x_{i+h})^2 \quad (3.15)$$

où H est le nombre total de couples de points, x_i représente les points échantillons et h est la distance ou pas d'échantillonnage

Les figures 3.13 et 3.14 présentent les semivariogrammes omnidirectionnels expérimentaux et théoriques des rendements du maïs et du soya. Les variations observées dans les semivariogrammes expérimentaux témoignent de l'existence d'une structure spatiale, car la semivariance augmente avec la distance. Les rendements du maïs étaient mieux décrits par un modèle sphérique ($R^2 = 0,995$), lequel est linéaire au voisinage de l'origine. Ce modèle a atteint un palier à la portée de 400 m. Au-delà de cette distance, les valeurs des rendements étaient indépendantes, c'est-à-dire qu'il n'y avait plus de corrélation spatiale entre elles. Quant au soya, il était caractérisé par un modèle gaussien ($R^2 = 0,972$), ce qui implique que le phénomène décrit est très continu. La dépendance spatiale était donc très grande entre les rendements du soya (Webster, 1985). Ce modèle a atteint son palier de manière asymptotique à environ 95 % de la portée. Celle-ci est très grande dans le cas du soya, ce qui signifie que les rendements étaient relativement homogènes et variaient faiblement d'un point à un autre du champ relativement au maïs.




Figure 3.13 : Semivariogramme des rendements du maïs




Figure 3.14 : Semivariogramme des rendements du soya

Cela a d'ailleurs été confirmé par les rapports *pépité/palier* qui ont exprimé une variabilité spatiale relative de 55 % pour le maïs contre 35 % pour le soya. Ainsi, les deux cultures ont montré l'existence de structures spatiales pouvant être dues à plusieurs facteurs tels que la topographie, la fertilité du sol, les maladies, les mauvaises herbes ou le climat.

3.4.3.2 Interpolation des rendements agricoles

Les données issues d'un capteur de rendement agricole sont un ensemble de points distincts. Ces points sont interpolés selon une grille régulière de dimension donnée afin de générer une carte montrant la distribution spatiale des rendements. Parmi les méthodes d'interpolation couramment utilisées, nous avons choisi le krigeage, car en plus d'estimer la valeur d'un point quelconque, il calcule également la variance correspondante, ce qui permet d'apprécier la qualité de l'interpolation (Webster, 1985). Le krigeage interpole un point en tenant compte de la combinaison linéaire pondérée des points voisins. Les paramètres caractéristiques requis pour le fonctionnement de cette méthode ont été déterminés à l'aide des semivariogrammes expérimentaux précédents. Les variations des coefficients de corrélation entre les rendements interpolés et le NDVI pour différentes résolutions spatiales nous ont permis de définir une résolution optimale pour la carte (Figure 3.15). Nous avons remarqué que ces coefficients augmentaient avec la résolution spatiale jusqu'à un maximum avant de décroître progressivement. Cette tendance est la même pour le maïs et le soya.

Lorsque la dimension des cellules d'interpolation est élevée, le lissage des rendements devient important, ce qui a pour effet de réduire les erreurs moyennes d'interpolation liées à chacune de ces cellules (Birrel and Sudduth, 1996). Cependant, des cellules de très grandes tailles peuvent masquer les structures spatiales des rendements et des images et occasionner une perte d'information qui peut se traduire par une diminution de la corrélation. La résolution spatiale optimale est celle à partir de laquelle les corrélations commencent à diminuer.




Figure 3.15 : Variation des corrélations entre le NDVI et les rendements

Les résolutions optimales ont été fixées à 9 m et 12 m respectivement pour interpoler les rendements du maïs et du soya. C'est donc ces valeurs qui ont été utilisées pour la suite de cette recherche. En effet, si l'on tient compte du fait que les données étaient enregistrées par le capteur de rendements chaque fois que la moissonneuse se déplaçait d'environ sa largeur de coupe, les résolutions minimales respectives des cartes seraient de 3 m x 3 m et 7,5 m x 7,5 m pour le maïs et le soya. De plus, l'espacement des rangs des plants de maïs était de 0,75 m et de 0,40 m pour le soya, ce qui équivaut respectivement à 4 et 19 rangs par cellule interpolée à la résolution minimale contre 12 et 30 rangs à la résolution optimale. Le grand nombre de rangs inclus dans ces cellules d'interpolation pour la résolution optimale a permis de réduire les erreurs moyennes d'estimation par unité de surface récoltée par la moissonneuse.

Ces résultats sont en accord avec ceux de Zhang *et al.* (1999) et Willis *et al.* (1999) qui ont également montré que la corrélation entre les rendements agricoles et le NDVI augmentaient avec la résolution spatiale. Les premiers auteurs ont trouvé une résolution optimale variant entre 9 m et 12 m pour les rendements de soya et de maïs. Quant aux

seconds, ils ont trouvé de meilleurs résultats avec une résolution de 40 m. Toutefois, la résolution spatiale la plus répandue dans la littérature pour l'interpolation des données de rendements agricoles est celle à 10 x 10 m (Murphy *et al.*, 1995).

3.4.4 Autres données disponibles

Les autres données comme le LAI, la topographie et les propriétés physico-chimiques du sol n'ont pas subi de traitements particuliers. Une vérification générale de certains critères statistiques telles que la normalité et la dispersion a été suffisante pour montrer qu'aucune transformation de ces données n'était nécessaire (Annexes 3A et 3B). L'analyse géostatistique a cependant été appliquée à la topographie et aux propriétés physico-chimiques du sol avant de les interpoler par krigeage à une résolution identique à celle de la carte de rendement correspondante. Enfin, la carte d'élévation du terrain a été utilisée dans ArcView pour générer les cartes des pentes et d'orientation des pentes.

3.5 Conclusion

Le traitement et l'analyse des données disponibles ont permis de définir et de constituer la base de données nécessaires à l'application du MLP. La principale remarque est que la qualité et la quantité de ces données étaient adéquates pour mener à bien notre projet de recherche. Les dates d'acquisition des images AISA et des photographies aériennes ont été bien choisies, si bien que nous disposons d'au moins une image prise durant la période de croissance optimale du maïs et du soya. Cela est essentielle pour valider la première hypothèse de cette étude. Nous avons retenu deux images AISA (juillet et septembre) pour l'étude du maïs et trois photographies aériennes dans le cas du soya.

Notre principale contribution à ce chapitre méthodologique est le développement d'un algorithme de corrections et de traitements des données de rendements agricoles. La correction des erreurs qu'il effectue permet de réduire grandement la variabilité spatiale induite par des facteurs autres que les rendements du maïs et du soya. La possibilité de

traiter plusieurs aspects de la correction des rendements fait gagner du temps à l'utilisateur et diminue les risques d'erreurs liés à l'usage de plusieurs logiciels. De plus, sa simplicité et sa grande flexibilité permettent de l'appliquer à différents types de capteurs de rendements couramment utilisés en agriculture. Le fait de générer également les statistiques descriptives des données donne une idée sur la variabilité globale des rendements. Enfin, l'approche adaptative utilisée par cet algorithme permet de traiter individuellement chaque trajet de la moissonneuse. Une telle démarche améliore l'analyse de la variabilité spatiale des rendements agricoles comme nous le montrons dans la suite de cette recherche.

Chapitre IV

Variabilité spatiale des rendements agricoles et des images aéroportées

4.1 Introduction

La télédétection permet d'acquérir des informations sur le développement des cultures de façon instantanée et sur de grands espaces. La possibilité de relier ces informations aux anomalies de croissance donne aux agriculteurs l'occasion d'identifier les stress végétaux et de corriger leurs effets sur la qualité des récoltes. Bien que la carte des rendements documente bien la distribution spatiale de ces récoltes, elle ne permet pas d'identifier les facteurs limitant la croissance des cultures. L'approche utilisée pour y arriver a consisté à analyser dans un premier temps les variations spatiales de cette carte. Dans une seconde étape, ces variations ont été reliées aux paramètres du sol et aux données images à l'aide de l'analyse multivariée dans un logiciel comme Statistica (Statsoft, 1996).

L'objectif de ce chapitre est d'analyser dans un premier temps la variabilité spatiale des rendements du maïs et du soya et d'identifier les facteurs qui causent cette variabilité. Dans un deuxième temps, nous examinons le potentiel des images à discriminer les variations spatiales des rendements.

4.2 Statistiques descriptives des rendements

Les cartes des rendements du maïs et du soya ont été segmentées en trois classes homogènes à l'aide de l'algorithme de classification non-supervisée ISODATA (*Iterative self-organizing data analysis*) (ESRI, 1995b). L'analyse de ces cartes a montré que les plus bas rendements du maïs étaient localisées dans le secteur Nord du champ où les élévations étaient plus faibles (Figure 4.1 et Annexe 4A). Dans le champ du soya, les rendements faibles ont été retrouvés sur une petite superficie dans les secteurs Ouest et Est, mais leurs variations n'étaient pas liées aux élévations (Figure 4.2 et Annexe 4B). La moyenne des rendements du maïs était de 9,5 t/ha et de 3,89 t/ha pour le soya à l'échelle du champ (Tableaux 4.1 et 4.2). Les moyennes des rendements étaient statistiquement différentes entre elles à $p < 0,05$ (Kleinbaum *et al.*, 1988).

Le CV du maïs était presque le double de celui du soya, ce qui signifie que la variabilité spatiale du maïs était relativement plus élevée. Mais dans les deux cas, cette variabilité était plus importante dans les classes de faibles rendements. Les variations spatiales de rendements peuvent être liées de façon générale à plusieurs facteurs tels que les conditions physico-chimiques du sol, les pratiques agricoles, les conditions climatiques, les mauvaises herbes ou même les maladies.

Tableau 4.1 : Statistiques des rendements dans l'ensemble du champ

Statistique	MAÏS	SOYA
Moyenne (t/ha)	9,50	3,89
Écart type (t/ha)	1,32	0,28
CV (%)	13,90	7,20
Nombre de points	60468	2056

Tableau 4.2 : Moyennes des classes de rendements agricoles

	MAÏS ($n = 400$)		SOYA ($n = 300$)	
Classes de rendements	Moyenne (t/ha)	Écart type (t/ha)	Moyenne (t/ha)	Écart type (t/ha)
Faible	6,48 ^a	0,60	3,13 ^a	0,26
Moyen	9,15 ^b	0,31	3,53 ^b	0,13
Élevé	10,35 ^c	0,25	3,88 ^c	0,10

*Les valeurs suivies par la même lettre ne sont pas différentes à 95 %

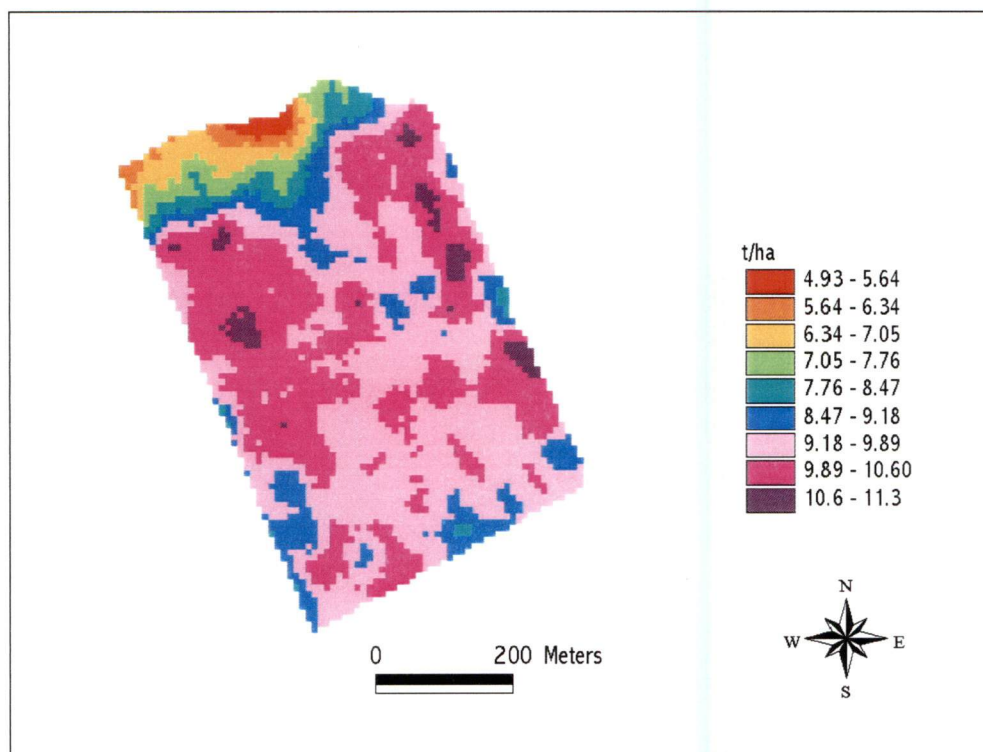


Figure 4.1 : Carte des rendements du maïs

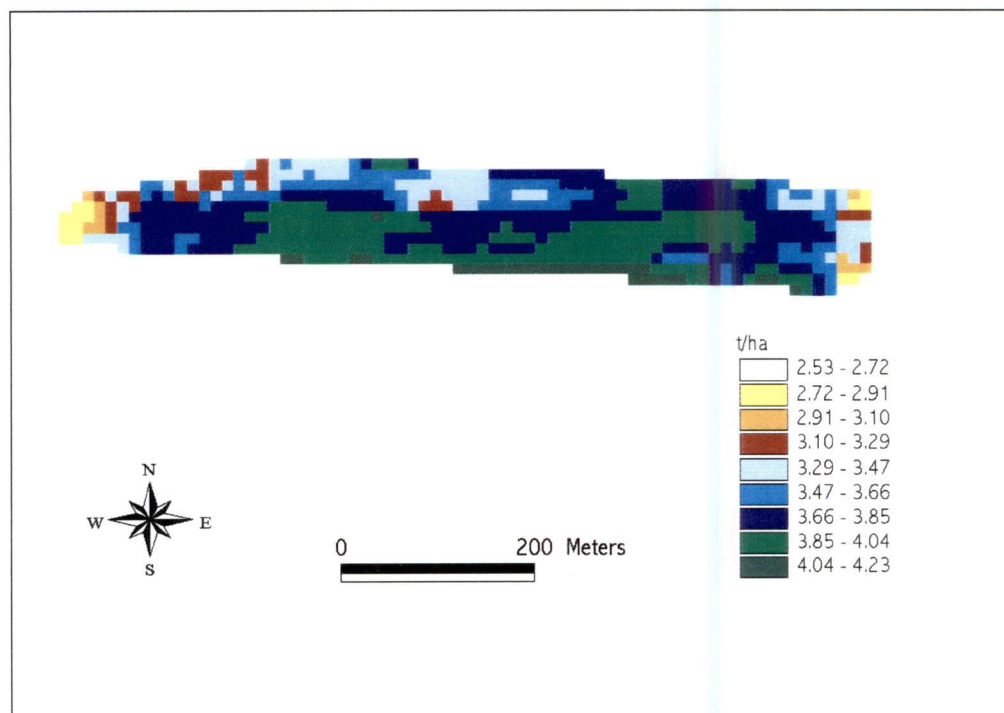


Figure 4.2 : Carte des rendements du soya

4.3 Facteurs explicatifs des variations des rendements

La variabilité des rendements agricoles est le résultat de l'intégration de plusieurs facteurs qui influencent la croissance des cultures durant la saison (Cassel *et al.*, 2000). Des analyses statistiques multivariées ont donc été appliquées à la topographie et aux éléments de fertilité du sol afin de mettre en évidence certains de ces facteurs.

Les corrélations entre les éléments de fertilité et les rendements du maïs et du soya étaient significatives ($p < 0,05$) (Annexes 4C et D). La matière organique et le pH du sol étaient les plus corrélés au rendement du maïs. Ils ont influencé la croissance du maïs selon une relation positive et négative respectivement. Toutefois, ils n'ont été des facteurs limitant que dans le secteur Nord du champ, qui était caractérisé par une dépression importante et une faible teneur en matière organique ($MO < 3 \%$). Le potassium et le phosphore étaient corrélés négativement avec les rendements du maïs. Mais leurs effets n'ont probablement pas été limitatifs pour ce dernier, car leurs teneurs à l'échelle du champ étaient plus ou moins uniformes et contrôlées. Ils ont donc joué un rôle moins important dans la variabilité spatiale des rendements du maïs. Quant aux rendements du soya, ils étaient négativement corrélés aux éléments de fertilité du sol (sauf avec la CEC) et ces relations étaient significatives ($p < 0,05$).

Les modèles de régression multiples ont montré que la fertilité du sol expliquait 64 % de la variance totale des rendements du maïs, contre 42 % pour les rendements du soya (Tableau 4.3). Cela démontre que ces éléments de fertilité ont été déterminants dans la variabilité spatiale des rendements du maïs et du soya. Cependant, l'apport exact et le type de relation de chaque élément peuvent varier d'un champ à un autre, d'une culture à une autre et à l'intérieur d'un même champ. Cet aspect n'est pas abordé dans cette étude, car il sort du cadre de notre thèse.

Tableau 4.3 : Régression multiple entre les rendements et les éléments du sol

Paramètres du sol	MAÏS ($n = 400$)		SOYA ($n = 300$)	
	R^2 ajusté	Statistique F	R^2 ajusté	Statistique F
Topographie	0,25	86,28	0,04	7,05
Éléments de fertilité	0,64	125,63	0,42	36,44

La corrélation entre les rendements du maïs et la topographie était significative ($p < 0,05$). Elle était positive avec l'élévation et négative avec les pentes, ce qui signifie que les rendements élevés se retrouvaient dans les zones de faibles pentes (Annexes 4C). Selon le modèle de régression multiple, les paramètres topographiques ont influencé la variabilité spatiale des rendements du maïs, car ils ont expliqué 25 % de la variance totale de ceux-ci. Cela confirme les résultats de plusieurs chercheurs qui ont montré que la variabilité spatiale des rendements agricoles est souvent influencée par la topographie du site (Yang *et al.*, 1998; Changere and Lal, 1997; Kravchenko and Bullock, 2000). Les rendements du soya par contre, n'ont affiché aucune corrélation significative avec l'élévation et la pente (Annexe 4D). En d'autres termes, leur variabilité spatiale n'était liée ni à l'élévation, ni à la pente du terrain. D'ailleurs le patron de variation générale des élévations de ce champ était très différent de celui des rendements du soya. Seule, l'orientation des pentes a indiqué une corrélation positive et significative de 0,20. Le modèle de régression multiple a également montré que la topographie n'a expliqué que 4 % de la variance totale des rendements du soya, ce qui est très faible comparé aux résultats obtenus avec le maïs.

La topographie du terrain n'est pas liée aux variations spatiales des rendements du soya, probablement parce que ses effets ont été atténués ou inhibés par des facteurs climatiques et pédologiques. En effet, la relation entre la topographie et les rendements peut être masquée par une accumulation d'eau dans le sol résultant des précipitations antérieures et accentuée par un très faible drainage (McConkey *et al.*, 1997). La culture peut donc se développer sur de fortes pentes et être alimentée convenablement en éléments nutritifs, si bien que sa croissance n'est pas ralentie. Il peut même arriver qu'avec une topographie prononcée, la redistribution de l'eau du sol soit très homogène et donc disponible aux plantes, surtout durant les périodes de faibles précipitations. Dans ce cas, les masses d'eau

n'étant pas très importantes, leur redistribution sous l'influence des forces de gravité causées par les gradients des pentes sera faible. Les mouvements de cette eau seront alors principalement définis par les forces de capillarité et d'adsorption à travers les micropores du sol (Sérélé, 1996). De tels processus peuvent avoir atténué la relation entre la variabilité spatiale des rendements du soya et la topographie du terrain.

4.4 Relation entre les rendements et les images

4.4.1 Indices de végétation (IV)

Le choix des bandes spectrales utilisées pour le calcul des IV a été effectué à partir d'une régression multiple entre les rendements de maïs et les réflectances du rouge et du PIR. Les bandes optimales étant celles dont la contribution au modèle de régression était plus significative (Annexes 4E). Ainsi, les bandes centrées sur les longueurs d'onde de 647 nm (rouge) et 900 nm (PIR) ont été sélectionnées pour l'image du 21 juillet. Dans le cas de l'image du 13 septembre, seules les bandes à 647 nm et 876 nm (PIR) ont contribué significativement au modèle. Le choix des bandes ne se posait pas pour le soya, car les photographies aériennes ne comptaient que trois bandes spectrales (vert, rouge et PIR).

L'utilisation de l'indice TSARVI requiert la connaissance des paramètres de la droite des sols nus du site étudié. Celle-ci représente la réflectance du sol indépendamment du taux d'humidité, et préserve les différences d'une bande à l'autre, particulièrement entre les canaux rouge et PIR (Bonn et Rochon, 1992). Cette réflectance du sol est également indispensable au calcul de l'indice WdVI (Bausch, 1993). La figure 4.3 représente la droite des sols nus du champ de maïs en début de saison. Celle-ci s'est ajustée très bien aux données avec un coefficient R^2 de 0,975. Les paramètres a_{rb} et b_{rb} du TSARVI ont été déterminés à partir de cette droite et ils sont respectivement de 0,76 et 0,024. Quant au rapport PIR_{sol} / VIS_{sol} du WdVI, il est égal à 1,20. Il faut signaler le WdVI et le TSARVI n'ont pas été calculés dans le cas du soya, car les photographies numérisées étaient non seulement en niveau de gris, mais en plus nous ne disposons pas de mesures de réflectance au sol, encore moins de réflectance dans le canal bleu (voir section 3.4.1).




Figure 4.3 : Droite des sols nus dans le champ de maïs

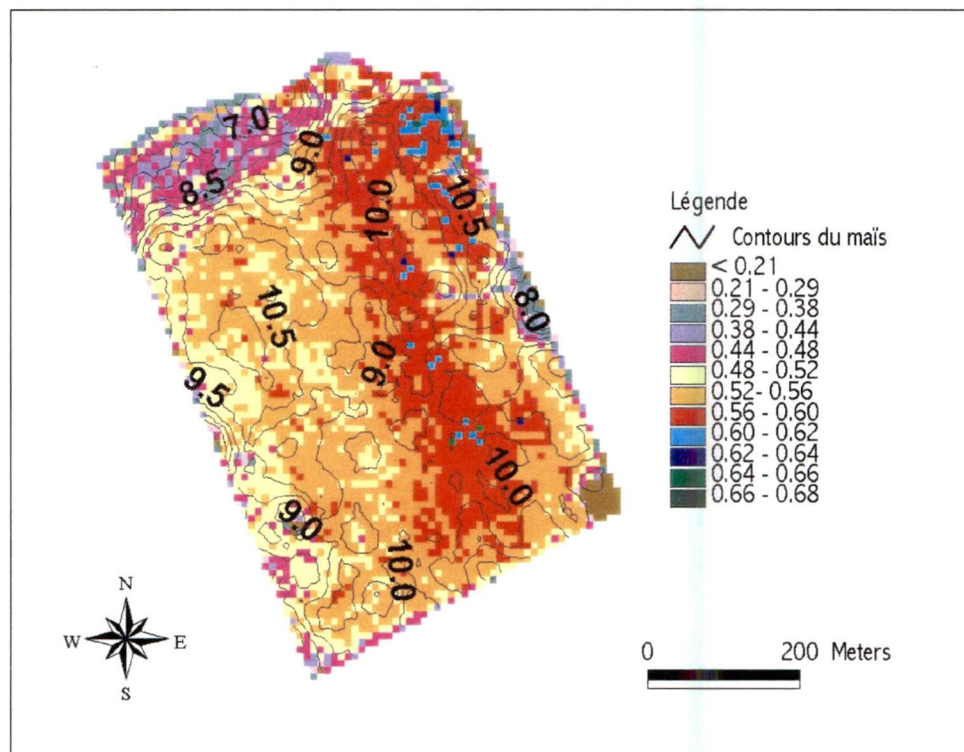
Les images des indices spectraux présentent un patron de variation qui est semblable à celui de la carte des rendements du maïs (Figure 4.4). Nous avons remarqué que les valeurs élevées de IV correspondent aux rendements élevés, alors que les faibles IV sont associés aux rendements faibles. L'analyse des variances montre que les IV ont très bien différenciés les rendements élevés des rendements faibles durant le mois de juillet (Tableau 4.4). Toutefois, le NDVI n'a pas discriminé les rendements élevés des rendements moyens, alors que le TSARVI a confondu les classes des rendements moyens et faibles. Seuls le WdVI et le SAVI ont permis d'identifier de manière significative les trois classes des rendements du maïs.

Parmi les IV calculés sur l'image du mois septembre, il n'y avait que le WdVI qui a discriminé les trois classes des rendements du maïs. Les valeurs du NDVI étaient constantes entre les trois classes, alors que le SAVI et le TSARVI ne faisaient pas de différence entre les classes de rendements faibles et moyens. Cette tendance témoigne d'une homogénéité spectrale entre les classes de rendements durant le mois de septembre, à cause de la sénescence progressive des plants de maïs.

Tableau 4.4 : Moyennes des indices de végétation du champ de maïs

Classes de rendement	NDVI		SAVI		TSARVI		WDVI	
	21 juil.	13 sept.	21 juil.	13 sept.	21 juil.	13 sept.	21 juil.	13 sept.
Élevé	0,83 ^a	0,70 ^a	0,78 ^a	0,59 ^a	0,51 ^a	0,40 ^a	0,55 ^a	0,34 ^a
Moyen	0,83 ^a	0,70 ^a	0,77 ^b	0,57 ^b	0,50 ^b	0,39 ^b	0,52 ^b	0,30 ^b
Faible	0,76 ^b	0,70 ^a	0,70 ^c	0,58 ^b	0,49 ^b	0,39 ^b	0,45 ^c	0,31 ^c
Moyennes	0,81	0,70	0,75	0,58	0,50	0,39	0,51	0,32

*Les valeurs suivies par la même lettre ne sont pas différentes à 95 % ($n = 400$)

**Figure 4.4 : Contours des rendements du maïs superposés au WDVI (21 juillet)**

Les indices NDVI et SAVI du champ de soya affichaient une tendance plus ou moins similaire au cas du maïs. Ils n'ont pas différencié les rendements élevés des rendements moyens, aussi bien pour les images du 5 et 30 juillet que pour celle du 5 septembre (Tableau 4.5). Les classes des faibles rendements du soya étaient cependant bien discriminées des deux autres classes de rendements. Dans l'ensemble, les faibles valeurs du NDVI et du SAVI correspondaient plus ou moins aux faibles rendements (Figure 4.5) et leurs moyennes évoluaient en forme de parabole durant la saison agricole.

D'une manière générale, nous remarquons que les données spectrales captent suffisamment bien les variations spatiales des rendements agricoles. La différenciation entre les classes de rendements faibles et élevés se fait très bien pour le mois de juillet. Cependant, il y a encore une confusion, particulièrement pour la discrimination entre les classes des rendements élevés et moyens d'une part, et entre les classes des rendements moyens et faibles d'autre part. La performance des IV était moins bonne en septembre, car le taux de couverture végétale était plus faible et la sénescence des cultures plus avancée. Nous examinons dans la section suivante l'intégration de données de texture afin de voir si elles apportent une information complémentaire qui pourrait améliorer la discrimination des classes de rendements du maïs et du soya

Tableau 4.5 : Moyennes des indices de végétation du champ de soya

Classes de rendement	NDVI			SAVI		
	5 juil.	30 juil.	5 sept.	5 juil.	30 juil.	5 sept.
Élevé	0,27 ^a	0,59 ^a	0,46 ^a	0,31 ^a	0,67 ^a	0,53 ^a
Moyen	0,28 ^a	0,56 ^a	0,46 ^a	0,32 ^a	0,65 ^a	0,53 ^a
Faible	0,21 ^b	0,48 ^b	0,42 ^b	0,24 ^b	0,55 ^b	0,48 ^b
Moyennes	0,25	0,55	0,45	0,29	0,62	0,51

n = 300

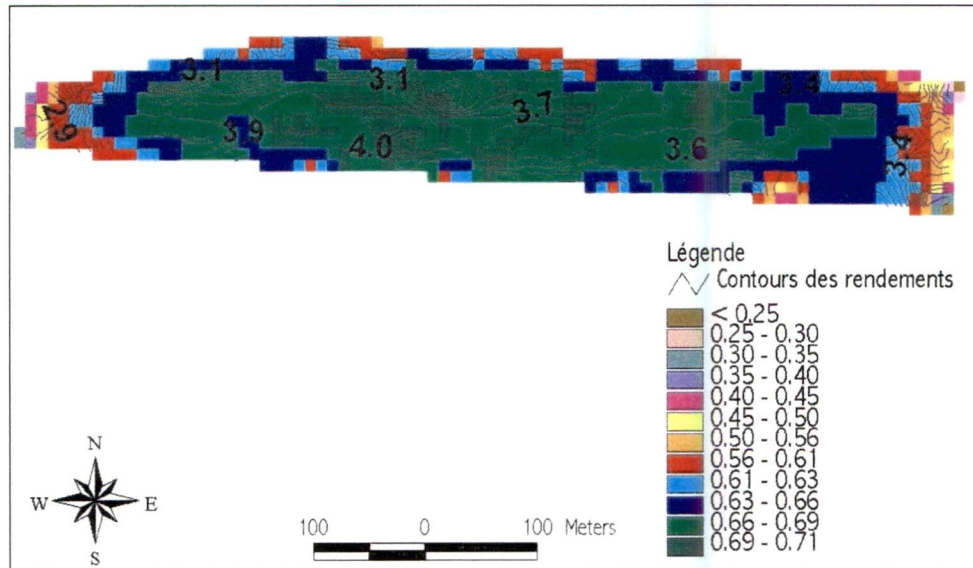


Figure 4.5: Contours des rendements du soya superposés au SAVI (30 juillet)

4.4.2 Indices de texture (IT)

La taille optimale de la fenêtre utilisée pour générer les images de texture a été déterminée graphiquement en considérant l'indice HOM (Figures 4.6 et 4.7). Elle représente la dimension des cellules à partir de laquelle le coefficient de variation de l'IT se stabilise. Ces tailles de fenêtre ont été fixées à 9 et 13 pixels pour le maïs et le soya respectivement. Cette différence de taille signifie que les plants du maïs étaient caractérisés par une texture plutôt grossière. Le soya dont les feuilles sont de petites dimensions mais très couvrantes au niveau du sol était mieux représenté par une texture fine et plus ou moins homogène. Mentionnons que dans le cas du maïs, l'image AISA étant en réflectance, nous avons d'abord réduit sa dynamique (transformation pour passer d'une image en 16 bits à une image en 8 bits) avant de calculer les matrices de cooccurrence qui s'appliquent à des données discrètes.




Figure 4.6 : CV du HOM en fonction de la taille de fenêtre pour le maïs




Figure 4.7 : CV du HOM en fonction de la taille de fenêtre pour le soya

Les paramètres de texture des images acquises en juillet n'affichaient pas de tendance de variation très nette entre les classes. Quant aux images de septembre, elles présentaient une relation linéaire entre les IT et les rendements agricoles. Les paramètres SMA et HOM ont diminué avec les rendements agricoles durant le mois de septembre contrairement à ENT et CON qui ont augmenté avec une diminution des rendements (Tableaux 4.6 et 4.7). Les classes des rendements étaient donc de plus en plus hétérogènes des zones élevées vers les zones faibles. Cette tendance de variation spatiale correspond très bien aux caractéristiques des IT, car le SMA et le HOM sont très élevés pour des textures uniformes ou homogènes, alors que le ENT et le CON affichent des valeurs élevées dans des zones contrastées ou hétérogènes (Haralick, 1979). Cette relation inverse entre la texture et la variabilité spatiale des classes de rendements du maïs et du soya s'explique par la différence de niveau de croissance végétale. En effet, une augmentation des teneurs en chlorophylle entraîne une augmentation de la biomasse, ce qui se traduit par des rendements agricoles élevés pour des conditions de croissance optimale (Toner *et al.*, 1997). De ce fait, la variation de biomasse est homogène et la texture uniforme pour la zone considérée. Ainsi, des indices comme le SMA et le HOM auront des valeurs faibles dans une telle zone, contrairement aux indices ENT et CON.

Les variations des paramètres de texture peuvent également être analysées en considérant l'aspect temporel des images. Le SMA et le HOM par exemple ont augmenté de l'émergence des cultures vers la sénescence, ce qui n'a pas été le cas du ENT et du CON qui ont plutôt diminué (Tableaux 4.6 et 4.7) dans les champs de maïs et de soya. Cela signifie que les variations de la texture dans ces champs étaient de plus en plus faibles lorsqu'on tendait vers la fin de la saison. La sénescence des plantes était donc plus ou moins homogène à l'échelle des deux champs, ce qui a créé une uniformisation de la texture. Enfin, l'analyse des variances a montré que la discrimination des classes de rendements du maïs à l'aide des IT était meilleure durant le mois de juillet. Seuls le SMA et le ENT ont discriminé les trois classes de maïs pour l'image du 13 septembre. Cependant, le pouvoir discriminant des IT était presque nul dans le cas des classes du soya, particulièrement pour le 5 juillet.

Tableau 4.6 : Moyennes des indices de texture du champ de maïs

Classes de rendement	SMA		ENT		CON		HOM	
	21 juil.	13 sept.	21 juil.	13 sept.	21 juil.	13 sept.	21 juil.	13 sept.
Élevé	0,93 ^a	1,31 ^a	1,21 ^a	0,69 ^a	1,11 ^a	0,16 ^a	0,83 ^a	0,93 ^a
Moyen	1,15 ^b	1,13 ^b	1,00 ^b	0,89 ^b	0,61 ^b	0,22 ^a	0,87 ^b	0,90 ^b
Faible	0,27 ^c	0,99 ^c	2,38 ^c	1,06 ^c	1,39 ^c	0,30 ^c	0,64 ^c	0,89 ^b
Moyenne	0,78	1,15	1,53	0,88	1,04	0,23	0,78	0,91

n = 400**Tableau 4.7 : Moyennes des indices de texture du champ de soya**

Classes de rendement	SMA			ENT			CON		
	5 juil.	30 juil.	5 sept.	5 juil.	30 juil.	5 sept.	5 juil.	30 juil.	5 sept.
Élevé	0,19 ^a	0,67 ^a	0,94 ^a	2,80 ^a	1,41 ^a	1,14 ^a	1,17 ^a	0,45 ^a	0,30 ^a
Moyen	0,21 ^a	0,77 ^b	0,85 ^a	2,91 ^a	1,26 ^b	1,21 ^a	1,41 ^a	0,38 ^b	0,34 ^a
Faible	0,24 ^a	0,72 ^a	0,63 ^b	2,81 ^a	1,44 ^a	1,69 ^b	1,44 ^a	0,39 ^b	0,59 ^b
Moyenne	0,21	0,72	0,80	2,84	1,37	1,35	1,34	0,41	0,41

n = 300**Tableau 4.7 : Moyennes des indices de texture du champ de soya**

Classes de rendement	HOM		
	5 juil.	30 juil.	5 sept.
Élevé	0,68 ^a	0,81 ^a	0,86 ^a
Moyen	0,65 ^b	0,83 ^b	0,85 ^a
Faible	0,68 ^a	0,83 ^b	0,81 ^b
Moyenne	0,67	0,82	0,84

n = 300

4.4.3 Régressions multiples entre les rendements et les indices

La matrice de corrélation montre que les rendements du maïs les IV calculés le 21 juillet affichaient des corrélations significatives et supérieures à 0,50 (Annexe 4F). Cela se traduit par le fait que la couverture végétale étant à son maximum en juillet, tous les IV ont affiché de fortes corrélations. Le TSARVI avait le coefficient de corrélation le plus élevée, suivi du SAVI, du WdVI et du NDVI avec des valeurs respectives de 0,63, 0,62, 0,53 et 0,53. Des corrélations significatives mais faibles existaient entre le rendement du maïs et les IT pour la même date de juillet : HOM ($r = 0,46$), ENT ($r = -0,43$), SMA ($r =$

0,36) et CON ($r = -0,13$). Cependant, l'amplitude de l'ensemble de ces corrélations a diminué de façon significative sur l'image du 16 septembre où le NDVI et le SAVI n'ont pas affiché de corrélation significative avec les rendements du maïs (Annexe 4G).

Les paramètres des modèles de régression multiple séquentielle indiquent que le contenu en information de l'image de septembre était beaucoup plus faible que celui de juillet. Le modèle qui intégrait les IV et les IT a expliqué 60 % de la variance des rendements du maïs en juillet (Figure 4.8) contre seulement 10 % en septembre. Lorsque les images des mois de juillet et septembre ont été combinées, la proportion de variance expliquée a augmenté à 68 % (Figure 4.9). La différence entre ces modèles de régression est due au fait que lorsqu'une culture est en pleine croissance, elle absorbe le rayonnement rouge et réfléchit le PIR (Blackmer and Shaepers, 1996). Mais lorsque son activité biologique atteint son maximum, il se produit une dégénérescence des cellules foliaires, ce qui provoque une baisse des teneurs en chlorophylle. La réflectance diminue alors rapidement dans le PIR et augmente lentement dans le visible. Par conséquent, la capacité de l'image à prédire les rendements diminue lorsqu'on tend vers la fin de la saison. Cela veut dire que le contenu en information de l'image est maximum lorsque celle-ci est prise durant la période de forte activité végétale. C'est la raison pour laquelle le modèle de régression du maïs est plus performant en juillet qu'en septembre.




Figure 4.8 : Régression entre les rendements du maïs, les IV et les IT (juillet)




Figure 4.9 : Régression entre les rendements du maïs, les IV et les IT (juillet et septembre)

Lorsque nous avons considéré séparément les indices spectraux et texturaux, nous avons remarqué que le modèle de texture avait été plus performant que le modèle spectral en juillet (Tableau 4.8). Le test de la différence a montré que les coefficients R^2 de ces modèles de régression étaient statistiquement différents durant le mois de juillet. Toutefois, cette différence a été plus réduite lorsqu'on a combiné l'image de juillet à celle de septembre. Nous avons constaté que le TSARVI, le SMA et le ENT ont mieux caractérisé la variabilité spatiale du maïs et que leur capacité à prédire les rendements était plus élevée.

La performance de la texture par rapport aux indices spectraux signifie que le rendement du maïs était assez hétérogène. Cette hétérogénéité peut être due aux conditions de fertilité du sol et de la topographie. Généralement, les classes de végétation homogènes sont mieux caractérisées par l'information spectrale, alors que les objets présentant une variabilité spatiale élevée sont mieux discriminés par les paramètres de texture, car ces derniers prennent en compte l'organisation spatiale des pixels de l'image (Peddle and Franklin, 1991). Ils peuvent ainsi servir d'indicateurs potentiels de la variabilité spatiale des rendements agricoles, surtout dans des champs très hétérogènes.

Tableau 4.8 : Régression entre les rendements du maïs, les IV et les IT

Dates d'acquisition	R ² ajusté			Statistique F			Meilleurs indices
	IV	IT	IV-IT	IV	IT	IV, IT	
21 juillet	0,40	0,51	0,60	163,58	130,35	108,6	tarvi et sma
16 septembre	0,09	0,02	0,10	13,53	7,22	11,94	tarvi et ent
21 juil et 16 sept.	0,50	0,52	0,68	100	78,10	88,10	*tarvi et sma

*TSARVI et SMA correspondant à l'image du 21 juillet ($n = 400$)



Les corrélations spatiales entre les IV et les rendements du soya étaient très faibles et non significatives à $p < 0,05$ pour l'image du 5 juillet ($r_{ndvi} = 0,02$ et $r_{savi} = 0,04$). Elles ont atteint leurs valeurs maximales avec l'image du 30 juillet ($r_{ndvi} = 0,43$ et $r_{savi} = 0,43$) (Annexe 4H), avant de décroître le 5 septembre ($r_{ndvi} = 0,20$ et $r_{savi} = 0,28$) (Annexe 4I). L'absence de corrélation significative sur l'image du 5 juillet s'explique par le fait que la couverture végétale était très peu couvrante à cette période de la saison. De ce fait, il était donc plus difficile de séparer la signature spectrale du soya de celle du sol. Les IT n'ont indiqué des corrélations significatives avec le soya que sur l'image du 5 septembre. Les coefficients de corrélation respectifs de HOM, du CON, de ENT et du SMA étaient de 0,09, -0,09, -0,11 et -0,09 le 5 juillet; de -0,18, 0,04, -0,04 -0,10 au 30 juillet; et de 0,27, -0,23, -0,35, 0,32 le 5 septembre.

Le pouvoir de prédiction des modèles de régression multiple séquentielle du soya était beaucoup moins élevé que celui du maïs. Les IV et les IT ont expliqué 24 % de la variance totale du soya pour les images combinées (30 juillet et 5 septembre) (Tableau 4.9). Lorsque nous considérons la chronologie de ces images, nous remarquons que l'image du 5 juillet n'a apporté aucune information comparativement aux deux autres images. Il faut également souligner que même si les modèles d'IT n'ont pas été aussi performants que dans le cas du maïs, ils ont cependant eu une contribution non négligeable. Car leur combinaison avec les IV a permis de passer de 19 % de la variance expliquée (IV seuls) à 24 % (IV et IT) (Figures 4.10 et 4.11). La contribution relative des IV et IT aux modèles de régression a reposé essentiellement sur le NDVI et le SAVI d'une part, et sur les indices HOM et ENT d'autre part.

Tableau 4.9 : Régression entre les rendements du soya, les IV et les IT

Dates d'acquisition	R ² ajusté			Statistique F			Meilleurs indices
	IV	IT	IV-IT	IV	IT	IV-IT	
5 juillet	0,02	0,01	0,02	0,21	3,67	3,65	ent
30 juillet	0,17	0,12	0,19	63,70	14,07	63,72	ndvi et hom
5 septembre	0,11	0,15	0,17	13,22	18,89	12,26	savi et ent
30 juil et 5 sept.	0,19	0,19	0,24	68,08	12,39	74,10	*ndvi et ent

*NDVI du 30 juillet et ENT du 5 juillet ($n = 300$)

**Figure 4.10 : Régression multiple entre les rendements du soya, les IV et les IT (30 juillet)****Figure 4.11 : Régression multiple entre les rendements du soya, les IV et les IT (30 juillet et 5 septembre)**

4.5 Conclusion

Ces résultats montrent que les effets de la topographie sur les rendements agricoles ne sont pas toujours systématiques. Bien d'autres facteurs comme les précipitations et la nature du sol contribuent à la redistribution de l'humidité du sol et des éléments nutritifs. Cependant, même si les effets directs de la topographie sont parfois faibles, ses effets indirects peuvent avoir un impact sur les rendements.

Aussi, bien que la fertilité du sol explique respectivement 42 % et 64 % la variance totale des rendements du soya et du maïs, elle n'a pas été incluse dans le réseau MLP. Notre but étant de proposer un modèle efficace avec peu de variables en entrée, nous avons évité d'utiliser trop de variables dont la collecte sur le terrain serait fastidieuse et coûteuse. Nous avons préféré utiliser la topographie comme donnée auxiliaire aux images, à cause de sa facilité d'acquisition et de son influence en milieu agricole.

Les résultats de cette étude montrent également que l'utilisation des bandes spectrales plus fines apporte beaucoup plus d'informations relatives à la croissance végétale par rapport aux bandes larges classiques. D'une manière générale, les indices spectraux et texturaux sélectionnés se révèlent comme de bons indicateurs de la variabilité spatiale des rendements agricoles, particulièrement avec les images hyperspectrales. Une combinaison de ces indices a permis d'expliquer 68 % de la variance totale du maïs, contre 38 % pour le soya. Il est toutefois important de signaler que l'efficacité de ces indicateurs dépend fortement de la période d'acquisition des images durant la saison.

L'essentiel de notre contribution dans ce chapitre porte sur deux points : l'étude des variations temporelles du contenu informationnel des images et l'utilisation quantitative de la texture pour décrire les variations des rendements agricoles. Nous avons montré que même avec des fines résolutions, les images ne sont pertinentes que lorsqu'elles sont acquises durant la phase de croissance où l'activité photosynthétique de la culture est à son maximum, généralement autour de la mi-juillet.

Nous avons également mis en évidence le potentiel des indices de texture comme indicateurs de la variabilité spatiale des rendements agricoles. L'application courante de ces indices se limitait à une utilisation qualitative pour la classification d'images en vue d'améliorer la séparation des classes d'objet spectralement identiques. Notre travail montre que ces paramètres peuvent être utilisés pour établir des modèles linéaires ou non entre les rendements et les variables biophysiques des cultures. Elles peuvent également être extraites des images de texture. De tels indicateurs seront très utiles dans les applications où les indices spectraux saturent pour des couverts végétaux très denses. Le potentiel de ces indicateurs est d'ailleurs mis à contribution dans le chapitre suivant pour caractériser le déficit en azote du maïs à partir de données du spectroradiomètre et des images AISA.

Chapitre V

Indicateurs spectraux et texturaux du déficit en azote du maïs

5.1 Introduction

La détection du déficit en azote est d'une grande utilité pour la gestion des fermes agricoles, car elle contribue à améliorer la production, à rendre efficace l'application d'azote à taux variable et à réduire la pollution des ressources en eau. Plusieurs études ont démontré la capacité de la télédétection à diagnostiquer les problèmes de croissance des cultures liés aux déficits végétaux, particulièrement au déficit en azote (Johnson and Billow, 1996; Vuilliot *et al.*, 1998). De plus, la télédétection permet une estimation rapide des caractéristiques végétales telles que la biomasse, le LAI et les teneurs en chlorophylles (Blackmer and Sheapers, 1996). Ces variables biophysiques étant positivement corrélées à la teneur en azote foliaire (Bausch and Duke 1996), leur mesure peut être utilisée comme tremplin pour caractériser le déficit en azote du maïs. En outre, ce déficit réduit entre autre la teneur en chlorophylle et change par conséquent les propriétés spectrales (Filella *et al.*, 1995). Cette relation entre les teneurs en azote, les constituants de la plante et le rayonnement solaire offre l'opportunité d'utiliser la télédétection comme outil pour investiguer la réponse des plantes due aux effets du déficit azoté.

L'objectif de ce chapitre est d'utiliser des indices spectraux et texturaux extraits d'images AISA pour mettre en évidence les effets du déficit en azote chez le maïs. La première partie du chapitre décrit les effets de ce déficit, tandis que dans la seconde partie, nous investiguons le potentiel des données spectroradiométriques et des images AISA à capter les réponses spectrales et texturales du maïs lié au déficit en azote.

5.2 Variation temporelle de l'indice foliaire


Dans l'ensemble du champ, le maïs s'est développé très rapidement en début de saison pour atteindre sa maturité vers la mi-août, puis la biomasse a diminué progressivement au fur et à mesure que la phase de sénescence s'est installée (Tableau 5.1 et Figure 5.1). Le LAI était plus élevé avec le taux de fertilisation, du moins avant la phase de sénescence. La parcelle 100N a connu un taux de croissance plus rapide relativement aux autres parcelles. Le LAI y a été plus élevé durant la saison, sauf pour le mois de septembre. Cependant, la croissance de la parcelle 64N a été ralentie en juillet et le LAI correspondant est plus faible que celui à 10N. Toutefois, le LAI du mois d'août montre que ce retard de croissance a été corrigé par la suite. La parcelle 64N présentait alors un LAI moyen plus élevé que celui de la parcelle 10N et assez proche de celui de la parcelle 100N dont la phase de croissance avait déjà atteint son maximum (Tableau 5.1). L'analyse des variances indique que les moyennes du LAI entre les parcelles sont statistiquement différentes, sauf durant le mois d'août (parcelles 64N et 100N).

Le ralentissement de la croissance du maïs de la parcelle 64N s'explique possiblement par l'existence d'un déficit hydrique qui a créé un dessèchement des horizons superficiels du sol, ce qui a provoqué une réduction de la disponibilité en éléments nutritifs (Garwood *et al.*, 1967), si bien que l'apport en azote a été moins efficace dans cette parcelle. La bordure Est de cette parcelle étant proche d'un chemin, l'action humaine peut également être responsable de cette diminution de la croissance du maïs. Globalement, nous avons observé une relation inverse entre les variations du LAI et celles de leurs coefficients de variation (CV) respectifs durant la saison.

Tableau 5.1 : Moyennes du LAI dans les parcelles fertilisées en azote (n = 30)

Parcelles	Juin	Juillet	Août	Septembre
10N (<i>n</i> = 9)	0,56 ^a ± 0,13	2,60 ^a ± 0,30	3,06 ^a ± 0,40	2,40 ^a ± 0,38
64N (<i>n</i> = 13)	0,75 ^b ± 0,12	2,50 ^b ± 0,32	3,75 ^b ± 0,52	3,18 ^b ± 0,45
100N (<i>n</i> = 8)	1,03 ^c ± 0,21	2,70 ^c ± 0,34	3,72 ^b ± 0,34	2,33 ^c ± 0,53
Moyennes	0,78	2,60	3,51	2,64
CV (%)	17	13	12	17

*les valeurs suivies par la même lettre ne sont pas statistiquement différentes

**Figure 5.1 : Variations du LAI dans les parcelles fertilisées en azote**

Les valeurs des CV moyens du LAI étaient plus élevées à l'émergence et à la sénescence et homogènes durant la phase de croissance maximale du maïs (Tableau 5.1). Cette variation en « cuvette » des CV est due à une augmentation des teneurs en chlorophylle qui a entraîné une augmentation plus ou moins homogène de la biomasse verte (juillet et août). Le couvert végétal étant plus important, les effets perturbateurs issus du sol par exemple ont été plus faibles. Par contre, durant les phases d'émergence et de sénescence du maïs, le LAI mesuré est influencé par les effets optiques du sol, lesquels introduisent une variabilité spatiale indépendante des conditions de la plante (Bausch and Duke, 1996). Cette variabilité a eu un impact sur le rendement agricole de la culture en fin de saison.

5.3 Variations des rendements du maïs

Les moyennes des rendements du maïs ont augmenté faiblement, mais linéairement avec le taux d'application d'azote. La variabilité spatiale traduite par les coefficients de variation de ces rendements est inversement proportionnelle aux taux d'application et est en accord avec les conclusions précédentes sur les variations du LAI (Tableau 5.2). Il est toutefois difficile de déduire un taux d'application optimum d'azote pour le maïs, car nous ne disposons que de trois parcelles tests. Même avec cinq différents taux d'application d'azote par site d'étude pour un total de cinq sites, Blackmer (1995) a trouvé une relation linéaire entre les rendements du maïs et le taux de fertilisation, sans pouvoir identifier la quantité d'azote à partir de laquelle les rendements se stabilisaient. Leurs travaux ont également montré que la différence de rendement entre les parcelles n'était significative que pour deux sites. Les résultats de l'analyse des variances des rendements de notre étude indiquent également une tendance similaire à celle des travaux de Blackmer et Sheapers (1996). En effet, bien que la différence de fertilisation ait eu un effet sur la croissance du maïs et que les rendements de la parcelle 64N aient été plus élevés que ceux de la parcelle 10N, ces derniers n'étaient pas statistiquement différents. Cela signifie que l'impact des facteurs perturbateurs de la parcelle 64N s'est prolongé durant la saison. De plus, la pente y était relativement plus élevée, ce qui accentue le drainage qui peut également contribuer à réduire le taux de croissance et donc les rendements du maïs.


Tableau 5.2 : Statistiques descriptives des zones fertilisées en azote

Traitement d'azote	Rendement (t/ha)	CV (%)	Minimum (t/ha)	Maximum (t/ha)
10N	9,37 ^a	13	4,17	11,17
64N	9,54 ^a	11	6,38	12,23
100N	9,89 ^b	9,5	6,63	12,55


*les valeurs suivies par la même lettre ne sont pas différentes à $p < 0,05$ ($n = 300$)

Les figures 5.2 (a, b et c) résument la relation entre les rendements du maïs et le LAI destructif issu des parcelles d'azote durant la saison. Ces deux variables ont affiché une relation linéaire positive dont l'amplitude suit la même tendance que celle entre les rendements du maïs et les indices spectraux. Cette relation est fonction du stade de croissance du maïs. Toutefois, même ces relations sont significatives, elles sont quand même faibles. Leurs valeurs étaient de 0,17, 0,26 et 0,32 le 7 et 22 juillet et 17 août respectivement. Le maximum de corrélation a été atteint en août, ce qui concordait avec la date de maturité physiologique du maïs située autour du 11 août.


L'ensemble des résultats précédents montre que le déficit en azote a eu un impact sur la croissance du maïs. La conséquence de ce déficit est exprimée dans les variations du LAI et des rendements entre les trois parcelles de maïs. Comme nous l'avons montré au chapitre IV, les paramètres des images aéroportées sont des indicateurs potentiels des variations spatiales des rendements agricoles. Ces rendements étant directement liés au LAI qui est positivement corrélé à la teneur en chlorophylles, lesquelles influencent les propriétés spectrales. Ces indicateurs pourraient être utilisés pour caractériser les effets du déficit en azote chez le maïs.



a) 7 juillet



b) 22 juillet



c) 17 août




Figure 5.2 : Relation entre les rendements du maïs et le LAI


5.4 Analyse des signatures spectrales du maïs

5.4.1 Spectres de réflectance mesurés à l'aide du GER

Les signatures spectrales des parcelles de maïs étaient très différenciées d'un niveau d'azote à un autre durant le mois de juin (Figure 5.3a). Les réflectances maximales des spectres ont augmenté avec le taux de fertilisation des parcelles, particulièrement dans le PIR. Elles étaient respectivement de 50 %, 40 % et 38 % dans les parcelles 100N, 64N et 10N. Cette tendance de variation était prévisible, car la réflexion du signal optique est principalement influencée par la quantité de biomasse ou de LAI dans le PIR (Fernandez *et al.*, 1994). Le comportement spectral du maïs était inversé dans le domaine du visible en juin; la réflectance y a diminué avec l'augmentation du taux de fertilisation.

La couverture végétale du maïs a été plus importante en juillet pour les trois parcelles, si bien que leurs réflectances respectives dans le PIR ont été plus élevées que pendant le mois de juin (Figure 5.3b). Le maximum de réflectance y était de l'ordre de 85 % dans la parcelle 100N, de 55 % pour la parcelle 64N et de 65 % dans celle de 10N. Comme on peut le constater, contrairement au mois de juin, la réflectance dans le PIR était plus élevée pour la parcelle à 10N relativement à celle à 64N. Cela témoigne d'un ralentissement de la croissance du maïs dans cette dernière parcelle. La réflectance n'y a pas changé significativement durant le mois d'août et le maximum correspondant était d'environ 52 % (Figure 5.3c). Quant aux parcelles 100N et 10N, leurs réflectances respectives ont baissé à 52 % et 42 %, signe d'une réduction de la biomasse végétale provoquée par le processus de sénescence. Ce dernier est la suite logique de la maturité physiologique du maïs et il est accentué pendant le mois de septembre (Figure 5.3d). Cependant, le maïs dans la parcelle 64N a connu une sénescence plus tardive, car son développement a été ralenti comparativement aux deux autres parcelles. Dans l'ensemble, le patron de variation globale des parcelles de maïs a été bien visualisé par les mesures du spectroradiomètre, même si ce dernier n'a pas la portée spatiale et la grande capacité d'échantillonnage des images aéroportées.

**a) 18 juin****b) 22 juillet****c) 27 août**



d) 16 septembre

Figure 5.3 : Spectres du maïs dans les parcelles d'azote

La grande particularité des signatures spectrales du maïs réside au niveau du domaine du visible (sauf pour le mois de juin). En effet, les réflectances y étaient faibles pour le maïs en condition de déficit azoté et élevées pour le maïs de la parcelle de référence (100N). Or, la croissance d'une culture qui est affectée par un déficit quelconque est ralentie. Par conséquent, les quantités de biomasse et de chlorophylles correspondantes seront plus faibles par rapport à une culture en condition normale (Schepers *et al.*, 1992). L'absorption du rayonnement solaire est alors moins importante dans le visible et les réflectances y sont plus élevées.

La variation inverse des réflectances du maïs dans le domaine du visible, a également été observée par Maraci *et al.* (1991) pour différentes conditions de croissance. Ils ont attribué la particularité de cette signature spectrale à la distribution de l'azote foliaire après le stade d'épiaison du maïs. Plusieurs études ont en effet montré que plus de la moitié de l'azote absorbé par le maïs se retrouve dans les graines entraînant ainsi une réduction simultanée de l'azote foliaire (Crafts-Brander *et al.*, 1984, Wolfe, 1984). Par conséquent, la proportion de chlorophylle foliaire qui est positivement corrélée avec la teneur en azote foliaire baisse régulièrement au fur et à mesure que les épis du maïs arrivent à maturité (Wood *et al.*, 1992). Ainsi, les réflectances mesurées durant la phase d'épiaison sont plus

élevées dans le visible chez maïs dont la croissance est ralentie. C'est ce processus métabolique du maïs qui est à la base des réflectances élevées dans le visible pour la parcelle de référence (100N) par rapport aux parcelles 64N et 10N qui accusaient un retard de croissance. Cette situation était toutefois moins évidente sur les images AISA, car celles-ci couvrent une plus grande surface et le signal mesuré est une intégration de la réponse de plusieurs composantes du maïs (tiges, feuilles et épis) et du sol.

5.4.2 Spectres de réflectance extraits des images AISA

Les spectres de réflectance extraits des images AISA sont représentés sur les figures 5.4 et 5.5 pour les mois de juillet et septembre respectivement. Tout comme pour les signatures spectrales mesurées au sol, les effets du déficit en azote ont été plus évidents dans le PIR. Les parcelles fertilisées ont présenté des réflectances très distinctes aussi bien sur l'image de juillet que celle de septembre. Cependant, la variation des réflectances au niveau du visible était très faible durant le mois de juillet, comparativement aux résultats obtenus avec le spectroradiomètre. Les effets potentiels du déficit hydrique observés dans la parcelle 64N étaient moins apparents sur l'image AISA du 21 juillet.

La similarité entre ces signatures spectrales et celles mesurées par le GER, nous fait dire que les effets de la différence de fertilisation sur la croissance du maïs ont été captées par les images AISA. Elles mettent aussi très bien en évidence la différence spectrale dans le PIR où la réflectance varie en fonction des taux de fertilisation, comme l'ont également observé Stanhill *et al.* (1972). Les images AISA montrent ainsi leur potentiel à suivre la croissance végétale en milieu agricole.

Ces résultats montrent d'une manière générale que le maïs est sensible à la différence de fertilisation en azote et que les effets de celle-ci ont été captés par le spectroradiomètre et les images AISA. Cela démontre que l'estimation quantitative de la variabilité du déficit en azote est réalisable à l'aide de ce type de données spectrales, plus particulièrement dans le domaine du PIR. En effet, le PIR est plus sensible aux taux d'azote à cause de leur influence sur la variation du LAI. Il s'agit donc d'une estimation indirecte liée à la géométrie de la plante.




Figure 5.4 : Spectres du maïs extraits de l'image AISA du 21 juillet




Figure 5.5 : Spectres du maïs extraits de l'image AISA du 13 septembre

5.5 Relation entre le LAI et la signature spectrale


Les figures 5.6 montrent que la dynamique temporelle des indices spectraux extraits des données GER se rapprochait de celle du LAI dans les trois parcelles du maïs. Ces indices et le LAI ont augmenté progressivement jusqu'à la maturité du maïs ($LAI = 3,5$) avant de décroître durant la phase de sénescence. En fait, une augmentation du LAI provoque une augmentation de la réflectance dans le PIR et une diminution dans le rouge. Ce changement de la signature spectrale entraîne une augmentation des indices spectraux (Aparicio *et al.*, 2000). Après la maturité physiologique de la culture, le processus inverse se produit et la diminution du LAI induit une augmentation de la réflectance dans le rouge, alors que celle dans le PIR, ainsi que la valeur de ces indices diminuent.

Les corrélations entre le LAI et les IV n'étaient toutefois pas significatives à $p < 0,05$ dans les trois parcelles (Tableau 5.3). De plus, les dates de leurs valeurs maximales ne coïncidaient pas avec celles du LAI pour chacune des parcelles. En effet, le maximum du LAI a été atteint le 10 août alors que celui des IV se situait approximativement au 30 juillet. La diminution des variations du LAI était également postérieure à celle des indices. Cela signifie que ces derniers ont capté les effets des changements internes de la structure du maïs alors que l'impact de ces changements ne s'était pas encore répercuté dans les fluctuations du LAI. Car la plupart du temps, les premiers symptômes des stress végétaux ne sont pas visibles, alors que les processus physiologiques des plantes subissent déjà leurs effets (Andrieu *et al.*, 1992).


Tableau 5.3 : Corrélations entre le LAI et les IV extraits du GER

Indices de végétation	10N ($n = 6$)	64N ($n = 6$)	100N ($n = 6$)	3 parcelles ($n = 18$)
NDVI	-0,27	-0,57	0,07	-0,20
SAVI	0,16	0,1	0,07	0,11
TSARVI	-0,17	0,00	0,11	0,01
WDVI	0,03	-0,34	-0,07	-0,08


N.B : Aucun des coefficients de corrélation de Pearson n'est significatif à $p < 0,05$



a) Parcelle de maïs à 10N



b) Parcelle de maïs à 64N



c) Parcelle de maïs à 100N

Figure 5.6 : Variations du LAI et des indices spectraux du GER

Le potentiel des indices spectraux et texturaux à caractériser les variations du LAI pour différents taux d'azote a été également mis en évidence à l'aide de l'image AISA acquise le 22 juillet. Tout comme dans le cas du GER, les indices spectraux n'ont montré aucune corrélation significative ($p > 0,05$) avec le LAI dans les parcelles 10N et 100N (Tableau 5.4). Des corrélations positives et significatives ($p < 0,05$) ont cependant été observées pour la parcelle 64N et pour les données des trois parcelles mises ensemble. Le WDV I extrait des images AISA s'est distingué par un coefficient de corrélation plus élevé que les autres indices de végétation.

Le LAI a été également corrélé avec certains indices de texture extraits des trois parcelles mises ensemble (Tableau 5.4). Le SMA¹ et le HOM² ont ainsi indiqué des corrélations significatives ($p < 0,05$) de 0,48 et 0,38 respectivement. Le modèle de régression multiple séquentiel basé sur ces indices de texture a permis de prédire le LAI avec un coefficient R^2 significatif ($p < 0,05$) de 0,20, contre un coefficient de 0,30 pour le modèle basé sur les IV. Il n'y a que les indices SMA et WDV I qui ont été inclus dans ces modèles de régression, car seuls leurs contenus relatifs en information étaient significatifs ($p < 0,05$).

Tableau 5.4 : Corrélations entre le LAI et les indices extraits de l'image AISA du 22 juillet

Indices de végétation	10N ($n = 9$)	64N ($n = 13$)	100N ($n = 8$)	3 parcelles ($n = 30$)
NDVI	0,62	0,66*	0,58	0,52*
SAVI	0,62	0,66*	0,58	0,52*
TSARVI	0,50	0,69*	0,53	0,56*
WDVI	0,42	0,78*	0,47	0,57*
HOM	0,63	0,45	0,46	-0,38*
SMA	0,65	0,42	0,27	0,48*
ENT	-0,61	-0,36	-0,33	-0,30
CON	-0,53	0	0,48	-0,27

*Coefficient de corrélation de Pearson significatif à $p < 0,05$

¹ Second Moment Angulaire

² Homogénéité

Même si le pouvoir de prédiction du LAI par le modèle basé sur le WDVl est plus élevé que celui basé sur le SMA, ces résultats montrent que la texture intercepte bien une quantité non négligeable d'information pouvant être très utile dans le domaine agricole. Son apport peut ainsi contribuer à améliorer la prédiction des variables biophysiques et aider à caractériser la variabilité spatiale induite par le déficit en azote. Cela est d'autant plus vrai, car cette variabilité spatiale exprimée par les fluctuations de la biomasse végétale se traduit par une augmentation de la variance des réflectances de l'image (Murase *et al.*, 1995).

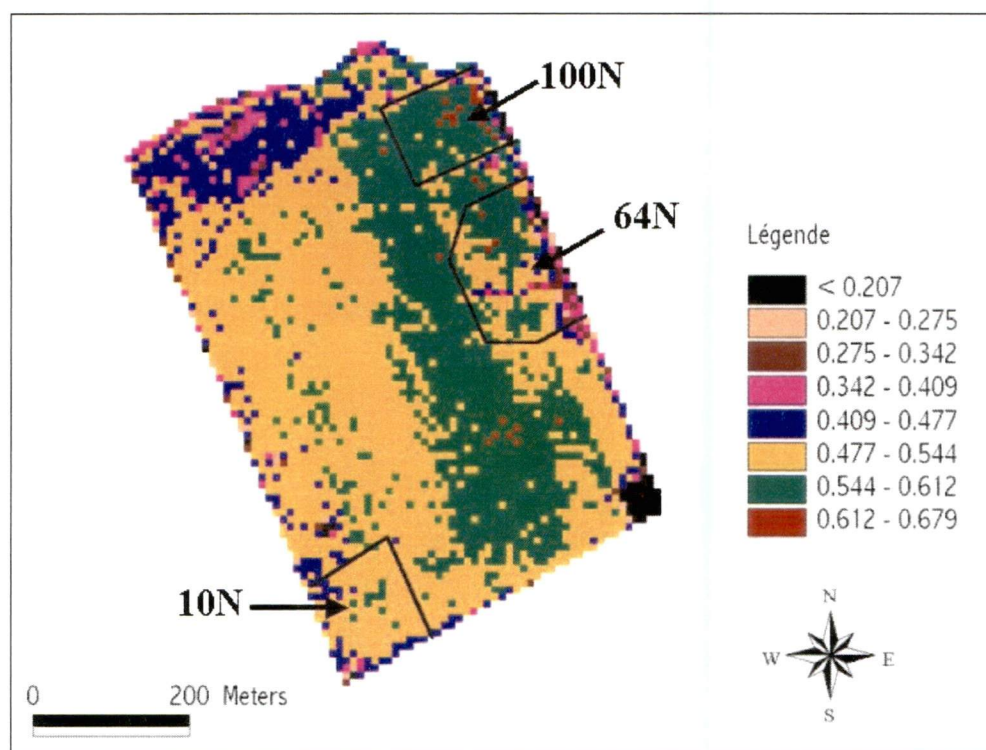
5.6 Discrimination des parcelles de maïs par les indices

Le test de la différence des moyennes a été appliqué aux indices spectraux et texturaux extraits des deux images AISA afin d'observer les effets de la différence de fertilisation azotée sur les réponses spectrales du maïs. Les moyennes des indices spectraux sont significatives ($p < 0,05$) entre elles (Tableau 5.5). Ils discriminent bien la végétation saine (100N) de celle en condition de déficit azoté (64N et 10N). En générale, les réponses spectrales du maïs sur l'image de juillet correspondent bien à la différence de fertilisation. La tendance de variation a toutefois changé durant le mois de septembre où la parcelle 100N qui était sénescence possédait les plus faibles valeurs d'indices, alors que la parcelle 64N dont la croissance a été retardée avait des indices plus élevés. La parcelle 10N, également en sénescence s'est retrouvée avec des valeurs moyennes (mais plus faibles comparativement au mois de juillet). Ce patron de variation des IV était similaire à celui du LAI durant la saison. La figure 5.7 montre que le retard de croissance observé dans la parcelle 64N est principalement dû à un facteur humain. En effet, la limite Est du champ est dominée par une bande de pixels de faibles valeurs qui traduisent un développement moins optimal du maïs durant le mois de juillet. La surface de cette bande est plus grande au niveau de la parcelle 64N, ce qui réduit d'une certaine manière sa moyenne. En fait, cette limite est un chemin d'accès à deux champs et l'activité humaine y est fréquente, ce qui a donc principalement influencée le maïs de la parcelle 64N.

Tableau 5.5 : Moyennes des indices spectraux des images AISA

Traitement d'azote	NDVI		SAVI		TSARVI		WDVI	
	21 juil.	13 sept.	21 juil.	13 sept.	21 juil.	13 sept.	21 juil.	13 sept.
10N	0,82 ^a	0,73 ^a	0,76 ^a	0,58 ^a	0,50 ^a	0,39 ^a	0,50 ^a	0,31 ^a
64N	0,81 ^b	0,72 ^b	0,76 ^a	0,60 ^b	0,49 ^b	0,40 ^b	0,52 ^b	0,35 ^b
100N	0,84 ^c	0,66 ^c	0,79 ^c	0,54 ^c	0,52 ^c	0,36 ^c	0,58 ^c	0,30 ^c

* Les moyennes suivies par la même lettre ne sont pas différentes ($p > 0,05$); les valeurs entre parenthèses représentent les écarts types ($n = 400$)

**Figure 5.7 : Variations du WDVI dans les parcelles fertilisées (21 juillet)**

L'analyse des variances a été appliquée à chacune des images afin de mettre en évidence la capacité des IV et IT à discriminer les zones de déficit en azote (Annexes 5A et 5B). Nous remarquons que le WDVl du mois de juillet se distingue par une plus grande sensibilité aux effets de la différence de fertilisation. Il explique 26 % de la variance totale contre 11 %, 9 % et 7 % pour le TSARVI, le SAVI et le NDVI respectivement. Le pouvoir discriminant du WDVl est encore plus élevé sur l'image du mois de septembre où il décrit 40 % de la variance due au déficit en azote. Cependant, cette proportion de variance expliquée n'est pas très différente de celle du TSARVI, NDVI et SAVI qui mettent en évidence respectivement 39 %, 38 % et 31 % de la variance totale. Ainsi, les indicateurs spectraux discriminent en moyenne 37 % de la variance totale des effets du déficit azoté, contre seulement 13 % durant le mois de juillet. Cela s'explique par le fait que la différence de LAI causée par le déficit en azote est plus grande en septembre qu'en juillet. Elle est en moyenne de $\pm 0,57$ et $\pm 0,17$ respectivement (Tableau 5.6). Cette différence a été captée par le PIR qui détermine la tendance générale des IV, car les variations des réflectances entre les parcelles sont plus faibles dans le visible.

Les variations spatiales des IT ont permis de localiser les zones homogènes et hétérogènes du champ de maïs. Les variations du HOM montrent que le champ de maïs comportait très peu de zones hétérogènes (Figure 5.8). Celles-ci étaient situées dans les secteurs Nord, Sud et Est, alors que la majorité du secteur centre était caractérisée par une très grande homogénéité. Nous avons remarqué également que les parcelles 100N et 10N étaient assez homogènes, comparativement à la parcelle 64N. Les différences de moyennes des paramètres de texture des parcelles de maïs n'étaient pas significatives pour les indices HOM, SMA et ENT (Tableau 5.3). Cependant, le pouvoir de discrimination des classes d'azote a augmenté en septembre. Lorsqu'on a considéré la variance inter-parcelle, les IT se sont avérés moins efficaces que les IV. Les variances moyennes expliquées par ces indices étaient respectivement de 7 % et 11 % pour les images de juillet et septembre. Pris individuellement, aucun des IT n'a mis en évidence plus de 15 % de la variance totale entre les parcelles d'azote. Cette augmentation du pourcentage de variance expliquée confirme l'analyse précédente de la tendance de variation des CV du LAI selon laquelle

les parcelles sont plus hétérogènes en début et en fin de saison. Entre ces deux périodes, la végétation croît régulièrement, ce qui entraîne une homogénéisation de sa surface.

Tableau 5.6 : Moyennes des indices de texture extraits des images AISA

Traitement d'azote	SMA		ENT		CON		HOM	
	21 juil.	13 sept.	21 juil.	13 sept.	21 juil.	13 sept.	21 juil.	13 sept.
10N	0,87 ^a	1,18 ^a	1,41 ^a	0,85 ^a	1,01 ^a	0,23 ^a	0,82 ^a	0,91 ^a
64N	0,61 ^b	1,01 ^b	1,95 ^b	1,07 ^b	2,12 ^b	0,43 ^b	0,72 ^b	0,88 ^b
100N	0,83 ^a	1,44 ^c	1,38 ^a	0,59 ^c	1,52 ^c	0,12 ^c	0,82 ^a	0,94 ^c

* Les moyennes suivies par la même lettre ne sont pas différentes ($p > 0,05$); les valeurs entre parenthèses représentent les écarts types ($n = 400$)

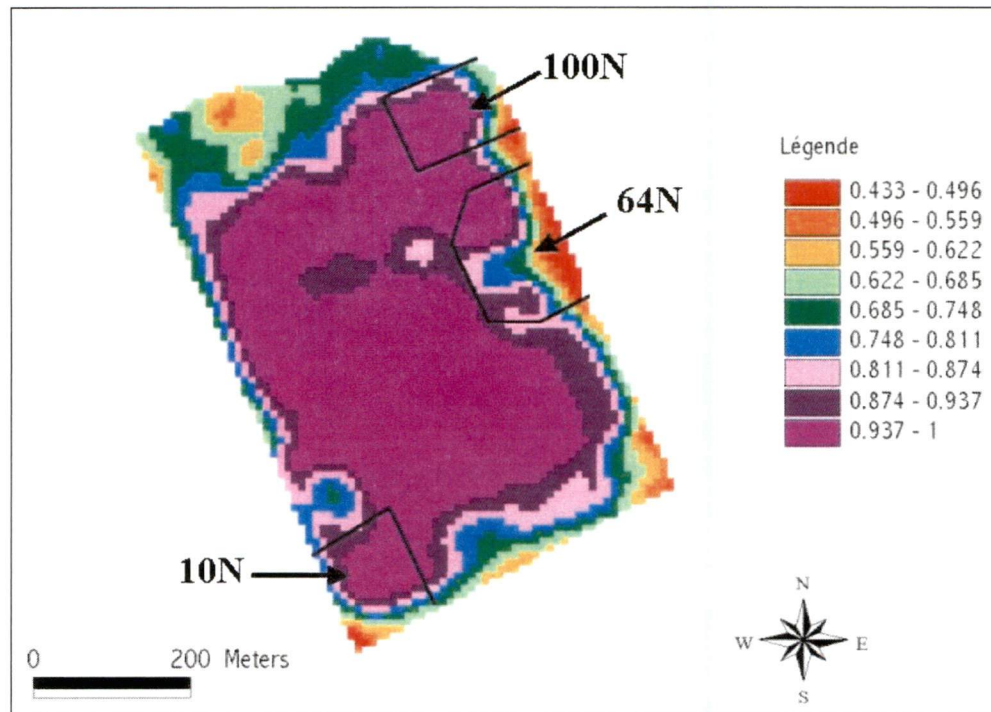


Figure 5.8 : Variations du HOM dans les parcelles fertilisées (21 juillet)

5.7 Conclusion

Ces résultats montrent que les données spectroradiométriques et les images AISA constituent une bonne source d'informations pour discriminer la variabilité spatiale et temporelle des cultures liées à un déficit en azote. La réponse spectrale du maïs à la différence de fertilisation azotée est très perceptible aussi bien dans les variations du LAI que dans celles des rendements du maïs. Celle-ci est aisément détectée à l'aide des données hyperspectrales, particulièrement dans la région du PIR. Les variations des indices WDV et TSARVI montrent que ces derniers sont plus sensibles aux variations des effets du déficit en azote. Au niveau des paramètres de texture, le SMA se révèle comme un indicateur potentiel de ce type de stress végétal. Les fines résolutions spectrale et spatiale des images AISA donnent une plus grande variation des niveaux de gris, ce qui permet aux IT de discriminer les classes qui sont spectralement homogènes. Ils sont faiblement corrélés aux IV et peuvent être très pertinents dans la caractérisation et le suivi de la croissance végétale. L'intégration de l'ensemble de ces indices spectraux et texturaux dans un modèle de prédiction non linéaire comme le réseau MLP est réalisé dans le chapitre suivant. Le modèle qui en découle constitue un excellent outil de gestion pouvant être utilisé pour prévenir et corriger les problèmes de croissance des cultures.

Dans ce chapitre 5, notre contribution se situe au niveau de l'évaluation du potentiel des images AISA à caractériser les effets du déficit en azote sur la croissance du maïs. Nous avons montré comparativement aux données spectroradiométriques, que ces images permettent de détecter le patron de variation de la croissance du maïs durant la saison. Elles constituent une bonne source d'informations qui peut être pertinente en agriculture de précision pour la gestion de la variabilité spatiale et temporelle intra et inter parcellaire. La seconde contribution apportée dans ce chapitre concerne l'utilisation quantitative des indices de texture pour prédire le LAI et mettre en évidence les effets du stress en azote. Bien que l'apport de ces indices soit plus faible que celui des indices de végétation, ils disposent cependant d'un potentiel fort intéressant qui permet de mieux visualiser l'hétérogénéité spatiale des variables biophysiques.

Chapitre VI

Prédiction des rendements du maïs et du soya à l'aide du MLP

6.1 Introduction

La prédiction des rendements est d'un intérêt capital en agriculture, car cette connaissance permet d'évaluer les stratégies de gestion agricole. La carte des rendements permet de localiser facilement les problèmes de croissance des cultures à l'échelle du champ, ce qui permet aux producteurs d'apporter des corrections lors de la prochaine saison. En dépit de cette importance, les méthodes actuelles de prédiction des rendements sont limitées, car trop contraignantes. C'est dans ce contexte que nous utilisons différentes configurations du MLP comme nouvel outil en vue de prédire les rendements agricoles (Figure 6.1).

L'objectif de ce chapitre est d'évaluer la capacité du réseau MLP à prédire les rendements du maïs et du soya à l'aide des indices spectraux et texturaux (extraits des images AISA) et de données topographiques. Nous y abordons également les questions relatives à la réduction des intrants du MLP et l'impact des erreurs de la carte de rendement sur la performance de ce modèle.

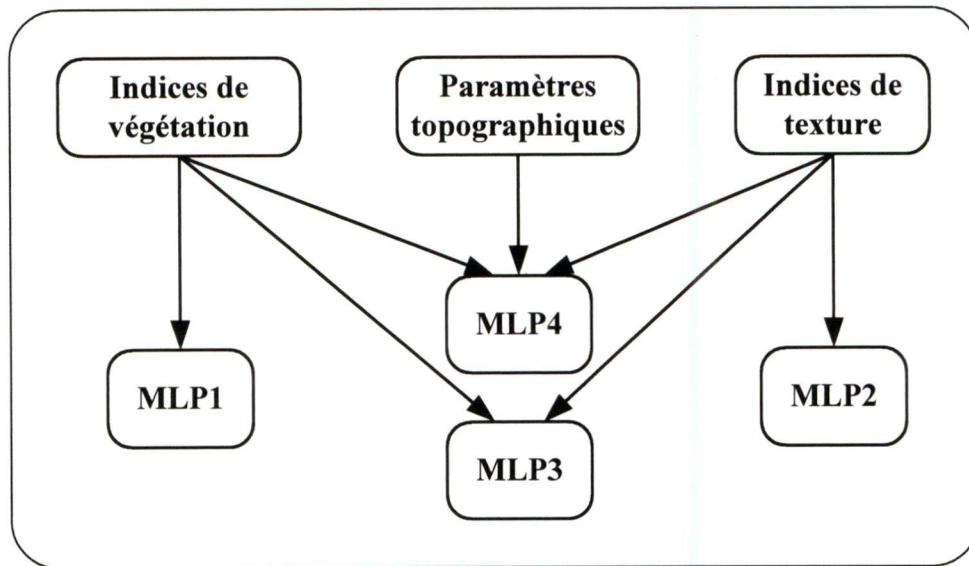


Figure 6.1 : Schémas de prédiction des rendements du maïs et du soya

Quatre schémas d'application du MLP ont été considérés pour la prédiction des rendements du maïs et du soya (Figure 6.1). Le premier schéma est représenté par la configuration MLP1 basée uniquement sur les IV. Ces derniers sont remplacés par les IT dans le MLP2. La combinaison des données spectrales et texturales définit la troisième configuration MLP3. Enfin, l'intégration des paramètres topographiques avec les IV et les IT fait l'objet du MLP4. Les modèles de MLP ont été développés à l'aide du simulateur neuronal de Statistica (StatSoft, 1998).

6.2 Développement et performance du MLP

Le processus de développement du MLP débute généralement par la mise en place d'une base de données, la sélection et la normalisation des variables d'entrée du réseau (Tarasenko, 1998). L'étape suivante vise à déterminer la configuration optimale de ce réseau en vue d'obtenir une meilleure performance. Les données de prédiction des rendements du maïs et du soya étaient composées de tous les indices spectraux et texturaux précédemment utilisés ainsi que des paramètres de topographie. Ces couches

d'informations ont été superposées dans le logiciel ArcView afin d'extraire des pixels échantillons. Le nombre total de pixels aléatoires extraits était d'environ 600 et 700 pour le soya et le maïs respectivement. Ces données ont ensuite été soumises à l'ADS et l'ACP pour réduire la dimension du modèle, puis regroupés en trois sous-ensembles (apprentissage, validation et test).

Les intrants du MLP n'ayant pas la même dynamique de variation, ils ont été normalisés par la méthode de la variable centrée réduite (Skidmore *et al.*, 1997). Les configurations du MLP ont été évaluées sur la base de deux paramètres : le coefficient de régression (R^2) entre les rendements observés et prédits et l'erreur RMS. Ces paramètres ont été calculés sur la moyenne de trois essais de prédiction des rendements. Pour déterminer la méthode de réduction des intrants qui génère les meilleurs résultats avec le MLP, nous avons calculé la statistique Z des coefficients R^2 (Kleinbaun *et al.*, 1988) :

$$Z = \frac{z_{ads} - z_{acp}}{\sqrt{1/(n_{ads} - 3) + 1/(n_{acp} - 3)}} \quad (6.1)$$

avec

$$z_{ads} = \frac{1}{2} \ln \frac{1+r_{ads}}{1-r_{ads}} \quad (6.2)$$

et

$$z_{acp} = \frac{1}{2} \ln \frac{1+r_{acp}}{1-r_{acp}} \quad (6.3)$$

où n_{ads} et n_{acp} sont respectivement la taille de la base de données pour les variables réduites par l'ADS et l'ACP, r_{ads} et r_{acp} sont les coefficients de régression du MLP pour chaque méthode de réduction des variables. Pour une configuration donnée, deux MLP sont considérés différents si la valeur absolue de Z est supérieure à 1,96 (à 95%), rejetant alors l'hypothèse nulle H_0^1 (Hair *et al.* 1998).

¹ L'hypothèse nulle H_0 affirme que les deux variables comparées sont égales.

6.3 Réduction de la dimension des intrants du MLP

L'annexe 6A résume les résultats de l'application de l'ACP aux données originales du champ de maïs. La transformation des quatre indices spectraux de chaque image a généré deux composantes principales (CP) significatives selon la règle de Kaiser² (Kaiser, 1960). Celles-ci expliquaient 95 % de la variance totale de l'image, d'où leur intégration dans le modèle MLP1. Quant au modèle MLP2, il a été développé et testé sur une proportion de variance de 87 % exprimée par les deux premières CP issues de la transformation des quatre paramètres de texture. Le MLP3 par contre a été mis en œuvre sur quatre CP significatives issues de la combinaison de tous les indices. Ceux-ci expliquaient 92 % de la variance totale de l'image.

Pour la prédiction des rendements du soya, les trois configurations précédentes du MLP ont également été évaluées sur une base de données constituées de deux à trois CP (Annexe 6B). La proportion de variance expliquée était respectivement de 87 %, 90 % et 84 % pour les modèles MLP1, MLP2 et MLP3 lorsque les deux images étaient combinées. Dans l'ensemble, la variance totale expliquée par les CP variait entre 84% et 95% pour le maïs et le soya, ce qui est suffisant pour prédire les rendements agricoles.

L'ADS a également été utilisée pour réduire la dimension des modèles MLP (Annexes 6C et 6D). Tous les modèles d'analyse discriminante formés par la combinaison de ces variables étaient significatifs ($p < 0,05$), ainsi que la contribution relative de chacune d'elle. Dans le cas du maïs, les configurations MLP1 et MLP2 intégraient 7 variables sur les 8 possibles, alors que la configuration MLP3 a fonctionné avec 11 variables sur les 16 possibles. Enfin, les intrants du modèle MLP4 étaient au nombre de 13 variables sur 17 pour la combinaison des images du 21 juillet et 13 septembre.

Tout comme pour le maïs, le nombre d'intrants sélectionnés par l'ADS dans le cas du soya était plus élevé que ceux de l'ACP dans certains cas (Annexes 6E et 6F). Le modèle

² Les composantes principales sont dites significatives lorsque leur valeur propre est supérieure à 1.

MLP1 a été développé et testé sur 3 des 4 variables, alors que le MLP2 a utilisé 4 variables sur 8 contre 4 variables sur 12 pour le modèle MLP3 pour l'ensemble des images de la saison. Quant au MLP4, il a fonctionné avec 6 variables sur 15.

L'ensemble des indices utilisés a permis d'expliquer une proportion importante de la variance totale des images AISA, aussi bien avec l'ACP qu'avec l'ADS. Ces derniers ont donc été intégrés dans le MLP pour la prédiction des rendements du maïs et du soya.

6.4 Prédiction des rendements agricoles par le MLP



Lorsqu'on a considéré les données spectrales extraites simultanément des deux images AISA (juillet et septembre), les modèles MLP1_{ADS} et MLP1_{ACP} ont généré des résultats similaires (Tableau 6.1). Ces deux modèles ont prédit les rendements du maïs avec des coefficients de régression identiques de 0,65 en apprentissage et de 0,64 durant le test. La performance du MLP a cependant augmenté dans le cas des paramètres de texture (MLP2_{ADS}). Les coefficients R^2 entre les rendements observés et prédits étaient de 0,88 et 0,86 en apprentissage et lors du test respectivement (Tableau 6.1). De plus les erreurs RMS liées au modèle MLP2_{ADS} étaient plus faibles par rapport à celles du MLP1_{ADS}. Toutefois la performance du MLP2 a diminué lorsqu'on y a introduit uniquement les CP générées par les IT comme intrants. Le coefficient R^2 pour les données tests était de 0,64 pour le MLP2_{ACP}, soit une diminution de 22 % par rapport au MLP2_{ADS}. Pourtant ces CP expliquaient une proportion cumulée de 87 % de la variance totale des IT.

L'intégration conjointe des IV et IT (MLP3) dans la base de données a amélioré la performance du réseau comparativement aux modèles précédents (Tableau 6.1). Les résultats du MLP3_{ADS} étaient supérieurs à ceux du réseau MLP3_{ACP}. Les coefficients R^2 obtenus lors du test étaient respectivement de 0,92 et 0,81 pour l'ADS et l'ACP (Figures 6.2 et 6.3). Les valeurs de la statistique Z montrent que la différence entre les coefficients de l'ADS et l'ACP était significative pour les modèles MLP2 et MLP3 (Annexe 6G), ce qui signifie que le MLP a mieux prédit les rendements du maïs avec les variables sélectionnées par l'ADS.

Tableau 6.1 : Prédictions des rendements du maïs (juillet + septembre)

Modèles de MLP		MLP1		MLP2		MLP3	
Méthodes de sélection		ADS	ACP	ADS	ACP	ADS	ACP
*Configuration du MLP		7-6-1 (250)	2-3-1 (100)	7-5-1(210)	2-3-1 (110)	11-9-1 (285)	4-4-1 (140)
Apprentissage (<i>n</i> = 230)	R^2	0,65	0,65	0,88	0,65	0,92	0,80
	<i>RMS</i>	0,95	0,98	0,57	0,99	0,36	0,70
Test (<i>n</i> = 230)	R^2	0,64	0,65	0,86	0,64	0,92	0,81
	<i>RMS</i>	0,95	0,97	0,62	1,01	0,37	0,67

*Les nombres entre parenthèse correspondent au nombre d'itérations

**Figure 6.2 : Prédiction des rendements du maïs par le MLP3_{ADS} (juillet - septembre)****Figure 6.3 : Prédiction des rendements du maïs par le MLP3_{ACP} (juillet - septembre)**

Bien que les performances des modèles MLP soient plus faibles dans le cas du soya, la tendance générale était semblable à celle du maïs pour toutes les images combinées. Les coefficients R^2 issus des modèles de MLP qui utilisent les variables de l'ADS étaient plus élevés par rapport à celles de l'ACP (Tableau 6.2, Figures 6.4 et 6.5). La différence entre ces coefficients n'était toutefois pas significative ($p > 0,05$) entre les modèles $MLP1_{ADS}$ et $MLP1_{ACP}$ d'une part, et entre les modèles $MLP2_{ADS}$ et $MLP2_{ACP}$ d'autre part (Annexe 6G). Autrement dit, la variance mise en évidence par les CP des modèles MLP1 et MLP2 permettait de représenter la majorité de l'information des données originales.



La similarité entre les résultats des modèles $MLP1_{ADS}$ et $MLP1_{ACP}$ s'explique par le fait que les deux premières CP qui constituent les intrants du $MLP1_{ACP}$ possédaient un contenu en information proche de celui des variables originales, car elles expliquaient 95 % de la variance totale des IV. Les faibles coefficients R^2 générés par ces modèles montrent que le contenu en information des indices spectraux est peu élevé pour ce champ. Ces résultats sont cohérents avec ceux des modèles de régression multiples, en ce que la performance du modèle de texture explique mieux la variabilité spatiale des rendements du maïs à cause de leur hétérogénéité (Séréfé *et al.*, 2000). De plus, les coefficients de R^2 du MLP sont supérieurs d'environ 15 % à ceux du modèle de régression multiple appliqué à ces mêmes données au chapitre 4. Les performances des différentes MLP n'étaient pas significatives ($p > 0,05$) dans le cas du soya, la direction de variance maximale identifiée par les CP coïncidait avec la direction du maximum d'informations requise pour la prédiction des rendements du soya.

D'une manière générale, nous remarquons que les configurations du MLP basé sur les CP ont généré des erreurs plus élevées, mais ont requis un faible nombre d'itérations relativement à celles utilisant les variables de l'ADS. Cela est dû au fait que l'ACP a réduit la grande quantité de variables initiales en seulement 2 à 4 composantes significatives qui n'expliquent qu'une partie de la variance totale. Il arrive parfois que cette réduction de la dimension des données occasionne une perte d'information, en ce sens que la proportion de variance expliquée par ces composantes ne représente pas toujours le maximum d'information.

Tableau 6.2 : Prédictions des rendements du soya (images juillet + septembre)

Modèles de MLP		MLP1		MLP2		MLP3	
Méthodes de sélection		ADS	ACP	ADS	ACP	ADS	ACP
*Configuration du MLP		3-3-1 (200)	2-3-1 (105)	4-4-1 (225)	2-3-1 (102)	4-4-1 (305)	3-4-1 (135)
Apprentissage (<i>n</i> = 190)	R^2	0,25	0,23	0,28	0,26	0,44	0,36
	<i>RMS</i>	0,25	0,26	0,23	0,25	0,20	0,24
Test (<i>n</i> = 190)	R^2	0,24	0,21	0,27	0,26	0,43	0,36
	<i>RMS</i>	0,28	0,27	0,23	0,26	0,21	0,25

*Les nombres entre parenthèse correspondent au nombre d'itérations

**Figure 6.4 : Prédiction des rendements du soya par le MLP3_{ADS} (juillet - septembre)****Figure 6.5 : Prédiction des rendements du soya par le MLP3_{ACP} (juillet - septembre)**

Le contenu en information de l'image acquise à la mi-saison (juillet) a été évalué séparément pour plusieurs configurations du MLP (Tableau 6.3, Figure 6.6). L'annexe G résume les statistiques de la comparaison de ces résultats avec ceux obtenus par les modèles précédents (deux images combinées). Le test a montré que les valeurs de Z étaient respectivement de 1,66, 1,78 et 1,78 pour les couples MLP1_{juil} - MLP1_{juil-sept}, MLP2_{juil} - MLP2_{juil-sept} et MLP3_{juil} - MLP3_{juil-sept}. Nous constatons que ces valeurs sont inférieures à 1,96, c'est-à-dire que ces différences ne sont pas significatives ($p > 0,05$). Le contenu informationnel de l'image de la mi-saison donne des résultats semblables dans le cas du soya (Tableau 6.4 et Figure 6.7). L'annexe 6G indique que les couples MLP1_{juil} - MLP1_{juil-sept}, MLP2_{juil} - MLP2_{juil-sept} et MLP3_{juil} - MLP3_{juil-sept} n'étaient pas également significatifs. L'hypothèse alternative H1³ a été rejetée et nous concluons que les images de mi-saison avaient un contenu en information très proche de l'ensemble des images de la saison, au point de générer des résultats similaires. Ceci s'explique par le faible pouvoir de prédiction des IV et IT des images de septembre relativement à celles de juillet, comme l'avait indiqué les modèles de régression.

Tableau 6.3 : Prédiction des rendements du maïs à l'aide de l'image du 21 juillet

Modèles de MLP		MLP1	MLP2	MLP3
*Configuration du MLP		3-3-1 (230)	4-3-1 (200)	6-6-1 (210)
Apprentissage ($n = 230$)	R^2	0,78	0,81	0,89
	RMS	0,91	0,58	0,54
Test ($n = 230$)	R^2	0,73	0,81	0,89
	RMS	0,86	0,61	0,60

*Les nombres entre parenthèse correspondent au nombre d'itérations

Tableau 6.4: Prédiction des rendements du soya à l'aide de l'image du 30 juillet

Modèles de MLP		MLP1	MLP2	MLP3
*Configuration du MLP		2-2-1 (108)	2-2-1 (109)	3-3-1 (204)
Apprentissage ($n = 190$)	R^2	0,26	0,28	0,41
	RMS	0,29	0,27	0,23
Test ($n = 190$)	R^2	0,24	0,27	0,40
	RMS	0,3	0,27	0,24

*Les nombres entre parenthèse correspondent au nombre d'itérations

³ L'hypothèse alternative H1 affirme que les deux variables comparées sont différentes.




Figure 6.6 : Prédiction des rendements du maïs par le MLP3_{ADS} (juillet)




Figure 6.7 : Prédiction des rendements du soya par le MLP3_{ADS} (juillet)

Lorsque nous observons la contribution relative des IV par rapport aux IT sur l'image de la mi-saison, nous remarquons que le modèle textural MLP2 a affiché des coefficients de prédiction des rendements du maïs plus élevés que le modèle des indices spectraux (Tableau 6.3). Dans le cas du soya, la texture s'est démarquée par des coefficients R^2 plus élevés mais statistiquement non différents de ceux issus de l'information spectrale (Tableau 6.4).

Ces résultats confirment le pouvoir de prédiction des indices de texture, comme l'avaient également montré Murase *et al.* (1995) en prédisant avec succès la teneur en eau foliaire du riz à l'aide d'un MLP. La texture permet effectivement de capter le patron des variations des rendements de maïs et de soya, car elle est reliée aux variations spatiales des réflectances de l'image qui sont causées par les variations géométriques et anatomiques de la surface des plantes (Haralick et Shanmugan, 1973).

Comparativement aux résultats précédents, l'introduction de la topographie dans le modèle MLP4 a faiblement amélioré les coefficients R^2 , mais elle a permis de diminuer énormément l'erreur RMS (Tableau 6.5). La topographie a contribué à augmenter la performance du MLP de l'ordre de 5% et 15% pour le maïs et le soya respectivement. Les pentes relativement basses de ces sites expliquent les faibles corrélations entre les rendements agricoles et les paramètres topographiques, d'où la faible amélioration de la capacité de prédiction des rendements par le MLP.

Tableau 6.5 : Apport de la topographie aux performances du MLP4

Cultures		Maïs		Soya	
Dates d'acquisition		Juil.	Juil.- sept.	Juil.	Juil - sept.
*Configuration du MLP		8-8-1 (220)	13-12-1 (235)	6-5-1 (310)	6-5-1(310)
Apprentissage	R^2	0,95	0,94	0,64	0,64
	<i>RMS</i>	0,36	0,05	0,17	0,16
Test	R^2	0,92	0,93	0,62	0,62
	<i>RMS</i>	0,37	0,07	0,18	0,17

*Les nombres entre parenthèse correspondent au nombre d'itérations

Sur l'ensemble des six cas d'application effectués pour le maïs et le soya, l'ADS s'est avérée plus performante que l'ACP de manière significative dans trois essais. L'hypothèse alternative H_1 ($\mu_1 \neq \mu_2$) a donc été acceptée pour ces cas et on peut conclure que l'ADS était mieux adaptée pour la réduction des intrants du MLP (Annexe 6G). Pour les trois essais restants, les coefficients de régression des deux méthodes ne sont pas statistiquement différents, mais ceux de l'ADS sont plus élevés (sauf pour le modèle MLP1 du maïs).

Enfin, les faibles performances du MLP sur le site du soya relativement au maïs sont dus au faible degré de corrélation entre les indices spectraux et texturaux et les rendements agricoles. En effet, ces indices étaient plus corrélés aux rendements agricoles dans le cas des images hyperspectrales que pour les photographies aériennes qui possèdent des bandes spectrales plus larges (de l'ordre 100 nm) (Gilabert *et al.*, 1996). Par conséquent, ces dernières ne captent pas certaines variations subtiles liées à la physiologie de la plante. Il faut aussi mentionner que la faible précision des photographies, causée par les problèmes associés à leur numérisation et au développement du film a dégradé le rapport signal - bruit et entraîné une perte d'informations, d'où les faibles coefficients de prédiction des rendements du soya. Ainsi, en plus de la qualité des données originales, leur contenu en information est également très important et influence grandement les résultats du MLP. Cela est d'autant plus vrai que l'apprentissage du MLP étant de type supervisé, les données originales servent de "vérité terrain" pour le calcul des erreurs de prédiction du réseau. C'est d'ailleurs une des raisons pour lesquelles nous avons tenu à faire une correction rigoureuse des données des rendements du maïs et du soya, car le MLP est sensible à la qualité des intrants.

6.5 Analyse de la sensibilité du MLP

L'analyse de sensibilité d'un modèle est importante dans la mesure où elle permet de connaître le comportement de ce dernier pour des conditions limites données. Pour ainsi évaluer la robustesse du réseau MLP dans cette étude, nous l'avons appliqué aux

rendements non corrigés du maïs et du soya. Les résultats obtenus ont été comparés aux précédents, ce qui a permis d'apprécier l'impact des erreurs de la carte des rendements.

Le tableau 6.6 présente les statistiques descriptives des rendements bruts et corrigés. Le CV des données brutes est de 2,45 et de 2,33 fois plus élevé que celui des données corrigées pour le maïs et le soya respectivement. Cette grande variabilité s'explique par le fait que le signal mesuré par le capteur de rendement est dominé par des hautes fréquences, le décalage spatial dû aux délais avant et arrière, les distorsions des points SPG, etc. (Birrel and Sudduth, 1996; Blackmore and Marshall, 1996). La corrélation entre les rendements bruts et les variables spectrales et texturales étaient plus faibles qu'avec les rendements corrigés, ce qui signifie une diminution de la proportion de variance expliquée. En d'autres termes, la qualité et la quantité d'informations véhiculées par ces données bruitées étaient moins bonnes.

La comparaison des résultats montre que la performance du MLP a été réduite de moitié lorsqu'il a été développé avec les données non corrigées (Tableau 6.7, Figures 6.8 et 6.9). Les coefficients de régression du modèle MLP3_{ADS} sont passés respectivement de 0,95 et 0,92 à 0,46 et 0,45 en apprentissage et lors du test dans le cas du maïs. L'impact des rendements bruités a également été très marqué dans le cas du soya où les coefficients R^2 étaient très bas. Ils étaient équivalents à 0,36 et 0,36, contre 0,64 et 0,62 pour les données corrigées. Quant aux moyennes de l'erreur RMS du MLP, elles ont augmenté substantiellement en passant de 0,36 t/ha et 0,21 t/ha (données corrigées) à 3 t/ha et 0,63 t/ha (données brutes) pour le maïs et le soya respectivement.

Les erreurs des données de rendements bruts ont créé des structures spatiales parasites si bien que les principales structures recherchées sont masquées. Ces erreurs étant d'origines diverses, leurs impacts varient énormément d'un endroit du champ à un autre. Par conséquent, ces perturbations ont empêché le MLP d'extraire la variabilité spatiale induite par les rendements du maïs et du soya, d'où sa faible performance. Tout comme Benediktsson *et al.* (1990), nous en arrivons à la conclusion que la performance des résultats du MLP est fortement reliée à la qualité des données initiales.

Tableau 6.6 : Statistiques des rendements agricoles avant et après correction

Paramètres statistiques	MAÏS		SOYA	
	non corrigé	corrigé	non corrigé	corrigé
Minimum (t/ha)	0	4,67	0,68	2,53
Maximum (t/ha)	16,83	11,30	5,72	4,24
Moyenne (t/ha)	9,57	9,50	3,64	3,89
Écart type (t/ha)	3,25	1,32	0,61	0,28
CV (%)	33,96	13,89	16,75	7,20

Tableau 6.7 : Prédictions du MLP avant et après correction des rendements (juillet)

Cultures		Maïs (MLP3 _{ADS})		Soya (MLP4 _{ADS})	
Traitements		non corrigé	corrigé	non corrigé	corrigé
Apprentissage	R^2	0,46	0,95	0,36	0,64
	<i>RMS</i>	2,93	0,36	0,63	0,20
Test	R^2	0,45	0,92	0,36	0,62
	<i>RMS</i>	3,08	0,37	0,64	0,22




Figure 6.8 : Prédiction des rendements du maïs par le MLP3_{ADS} (données non corrigées - juillet)




Figure 6.9 : Prédiction des rendements du soya par le MLP4_{ADS} (données non corrigées - juillet)

6.6 Conclusion

Le MLP a montré sa capacité à modéliser adéquatement les relations entre les rendements du maïs et du soya et les indices spectraux et texturaux. Les performances de ce réseau étaient plus élevées lorsque les deux types d'indices étaient intégrés conjointement dans le modèle. L'application du MLP aux IV et IT de l'image de la mi-saison a permis de valider notre première hypothèse de recherche. En effet, les tests statistiques ont montré que les résultats obtenus avec l'image de mi-saison (juillet) n'étaient pas statistiquement différents ($p > 0,05$) de ceux obtenus avec les images combinées (juillet et septembre). En d'autres termes, une image acquise durant la période où l'activité biologique de la plante est son maximum contient assez d'informations pour prédire les rendements du maïs et du soya au même titre qu'une combinaison d'images multitudes.

Les différents traitements effectués sur les données originales des rendements de maïs et de soya ont été essentiels pour réduire les structures spatiales indépendantes des variations de ces rendements. Les effets de tels traitements se sont reflétés dans les performances du MLP. La dégradation des résultats de ce dernier démontre que ses performances sont liées à la qualité des données sources.

Des deux méthodes de réduction des variables utilisées, l'ADS a généré les plus faibles erreurs RMS, ainsi que les coefficients R^2 les plus élevés comparativement à l'ACP. La supériorité de l'ADS sur l'ACP était beaucoup plus marquée dans les configurations du MLP qui combinent les paramètres spectraux et texturaux. Cette méthode de réduction des données est mieux adaptée au MLP, car elle ne change pas la variabilité contenue dans les données originales étant donnée qu'elle n'applique pas de transformation sur ces données, contrairement à l'ACP.

Nous avons démontré dans cette étude que, en plus de ses qualités en tant que méthode qualitative, le réseau MLP peut également être une excellente méthode quantitative. Nous avons réussi à intégrer peu de variables à fine résolution dans le MLP pour prédire adéquatement les rendements du maïs et du soya à l'échelle du champ. Ce modèle est un

outil très prometteur en milieu agricole, car en plus de générer de bons résultats, il est flexible et utilise des intrants facilement accessibles. Il s'intègre très bien dans le contexte agricole actuel à cause de ses nombreux avantages par rapport aux méthodes classiques connues.

Une autre contribution de notre travail, c'est d'avoir montré que malgré sa capacité à traiter des problèmes non linéaires, le MLP est sensible à la qualité des données qui lui sont présentées. Cette conclusion évite de prendre pour acquis pour acquis que même si on intègre « n'importe quoi » dans un réseau de neurones, il génère quand même de bons résultats. Notre étude va également encourager l'utilisation quantitative des paramètres de texture d'Haralick en milieu agricole, car ces derniers sont des variables prédictives potentielles des rendements agricoles et ils permettent de capter leurs structures spatiales.

Chapitre VII

Détection du déficit en azote du maïs à l'aide du MLP

7.1 Introduction

De nombreuses études ont montré que les concentrations d'azote foliaire et de chlorophylle étaient positivement corrélées entre elles et que cette relation pouvait servir à identifier les plantes présentant un déficit en azote (Schepers *et al.*, 1992; Blackmer, 1995). Les concentrations de chlorophylle sont ainsi directement quantifiées sur le terrain à l'aide d'instruments dont le principe est basé sur la relation empirique entre la transmittance et la chlorophylle (Pickielek and Fox, 1992). La précision de ces appareils est toutefois limitée par l'influence de la structure foliaire sur la transmission. De plus, la plupart des couverts végétaux qui subissent un stress en azote présentent généralement une forte hétérogénéité de pigmentation due à une variabilité de la sévérité du déficit. Cela pose alors le problème de la représentativité des échantillons mesurés sur quelques feuilles en quelques endroits du champ (Bausch and Duke, 1996). Par conséquent, il est nécessaire d'explorer d'autres méthodes de détection du déficit azoté qui sont efficaces et applicables à de grandes surfaces.

Dans cette perspective, une intégration des données spectrales et texturales dans un MLP est une voie potentielle. Le processus de détection des zones de stress en azote à l'aide des images et du MLP peut être ramené en réalité à un problème de classification d'objet où les limites des classes concernées sont déjà connues. Nous avons voulu vérifier si le MLP pouvait discriminer les réponses spectrales d'une parcelle de maïs en condition de stress azoté d'une parcelle de référence évoluant dans des conditions normales de croissance.

Nous avons également abordé les questions relatives à la sélection des intrants du MLP, à l'effet de la date d'acquisition de l'image et à la contribution de la topographie. Les scénarios de classification des parcelles de maïs ainsi que les différentes couches d'information sont les mêmes qu'au chapitre 6, c'est-à-dire : le MLP1 est basé uniquement sur les IV, le MLP2 utilise les IT, le MLP3 combine les IV et les IT et enfin le MLP4 intègre les paramètres topographiques avec les IV et les IT. Quant aux étapes d'apprentissage, de validation et de test du MLP, elles ont été effectuées sur une nouvelle base de données constituée de 750 pixels, à raison de 250 par parcelle.

7.2 Évaluation de la performance du MLP

La performance du MLP à discriminer les parcelles d'azote a été évaluée par la précision de la classification qu'il a effectuée sur les données qui lui ont été présentées. La mesure de cette précision permet d'évaluer la capacité du MLP à reproduire la représentation thématique du déficit en azote telle que perçue par les images.

Parmi les critères de quantification de la fiabilité d'une méthode de classification, la précision globale (ou taux de classification globale) et le coefficient Kappa (K) sont les plus connus et les plus utilisés (Cohen, 1960; Singh, 1986). Le premier critère est extrait de la matrice de confusion de la classification de l'image. C'est le rapport du nombre total de pixels correctement classifiés par le nombre total de pixels de l'image. Cette précision dépend toutefois de l'échantillonnage des pixels et elle ne tient pas compte des erreurs de

commission¹ et d'omission² liées à la classification. Par conséquent, nous avons utilisé en plus, le coefficient K. Ce dernier indique comment la méthode de classification évaluée se comporte par rapport à une allocation des pixels aux mêmes classes selon une méthode aléatoire. K est déterminé selon l'équation (7.1) pour chaque matrice de confusion (Congalton and Mead, 1983) :

$$K = \frac{n \sum_{i=1}^l X_{ii} - \sum_{i=1}^l (X_{i+} * X_{+i})}{n^2 - \sum_{i=1}^l (X_{i+} * X_{+i})} \quad (7.1)$$

où l est le nombre de lignes et de colonnes de la matrice, X_{ii} est le nombre d'observations de la ligne i et de la colonne i respectivement, X_{i+} est le total marginal de la ligne i , X_{+i} est le total marginal de la colonne i et n est le nombre total d'observations.

À partir du calcul de la variance du coefficient K de chaque matrice, on peut reformuler l'équation 6.2 du test Z afin de comparer deux classifications indépendantes effectuées sur un même ensemble de données (Cohen, 1960) :

$$Z = \frac{K_1 - K_2}{\sqrt{\sigma_{K_1}^2 + \sigma_{K_2}^2}} \quad (7.2)$$

où

$$\sigma_K = \sqrt{\frac{p_o (1 - p_o)}{n (1 - p_c)^2}} \quad (7.3)$$

avec

$$p_o = \sum_{r=1}^l X_{ri} \quad (7.4)$$

¹ L'erreur de commission exprime le nombre de pixels ajoutés à une classe mais qui en réalité appartiennent à une autre classe. L'analyse est faite sur les colonnes de la matrice de confusion.

² L'erreur d'omission exprime le nombre de pixels d'une classe qui sont classifiés dans une autre classe. L'analyse est faite sur les lignes de la matrice de confusion.

et

$$p_c = \sum_{r=1}^l X_{i+} * X_{+i} \quad (7.5)$$

Les résultats de deux classifications indépendantes sont considérés comme statistiquement similaires, si la valeur absolue de Z est inférieure à 1,96, sinon, elles sont différentes entre elles. Ce test a permis par la même occasion de comparer les deux méthodes de réduction des intrants du MLP (l'ACP et l'ADS).

7.3 Réduction des intrants du MLP

Lorsqu'on a combiné les images AISA de juillet et septembre, les IV et IT (MLP3) ont expliqué 88 % de la variance totale de l'image (Annexe 7A). Les quatre premières composantes principales (CP) sont significatives selon la règle de Kaiser (Kaiser, 1960). L'intégration de la topographie avec ces indices a permis d'augmenter le nombre de CP significatives à cinq pour le MLP4. Toutefois, la proportion de variance totale expliquée a diminué légèrement de 3 %.

Les résultats de l'application de l'ADS sont présentés aux annexes 7B et 7C. Les deux variables qui ont discriminé le mieux les parcelles d'azote sur les images de juillet et septembre combinées étaient par ordre décroissant le $WDVI_{\text{juillet}}$ et le $WDVI_{\text{septembre}}$ (modèle MLP3) et l'élévation et le $WDVI_{\text{juillet}}$ (modèle MLP4) (Annexe 7B). Le nombre d'intrants de ces modèles était respectivement de 7/16 et 11/19. Lorsqu'on a considéré séparément l'image du mois de juillet, le pouvoir discriminant le plus élevé a été attribué respectivement au $WDVI$ et $NDVI$; HOM et CON ; $WDVI$ et $NDVI$; l'élévation et le $WDVI$ associés aux modèles MLP1, MLP2, MLP3, MLP4 (Annexe 7C). Le nombre de variable d'entrée de ces MLP était de 4/4, 3/4, 6/8 et de 6/11 respectivement.

La diminution de 3 % de la variance expliquée par le MLP4 ne signifie pas que la contribution de la topographie est négligeable dans le modèle MLP, car la direction de

variance maximale des CP ne coïncide pas nécessairement avec la direction du maximum d'informations des variables originales (Wu and Massart, 1996). La classification des parcelles de maïs dans la section suivante infirme d'ailleurs ce dernier point.

La réduction des variables par l'ADS montre que le WDVl a été l'indice spectral le plus pertinent pour discriminer les parcelles d'azote. Cet indice est donc très sensible à la variation de biomasse qui reflète la réponse du maïs au déficit azoté. Les paramètres statistiques des modèles MLP3 et MLP4 montrent également que la contribution des IT est très faible relativement à celles des IV. Ces observations concordent bien avec les conclusions du chapitre 5. Par conséquent, un modèle MLP dont les intrants sont basés uniquement sur la texture de l'image aura un potentiel limité pour la discrimination des parcelles fertilisées en azote.

7.4 Discrimination des parcelles d'azote par le MLP

Les précisions globales et les coefficients K respectifs de la classification des parcelles fertilisées en azote sont résumés dans les tableaux 7.1 et 7.2 pour l'apprentissage et le test du MLP. Les résultats présentés concernent le cas des images combinées de juillet et septembre.

Nous remarquons que l'utilisation des variables extraites par l'ADS a augmenté la précision de la classification des parcelles d'azote par rapport à celles issues de l'ACP. Cette augmentation était en moyenne de 24 % pour les parcelles 10N et 64N, contre 13 % pour la parcelle 100N en apprentissage et lors du test pour le MLP3. La tendance était la même pour le schéma de classification de type MLP4. Les meilleurs résultats de ce dernier ont été obtenus avec l'ADS. Toutefois la différence entre les taux de classification individuelle des parcelles a été moins élevée que dans le cas du MLP3 (Figure 7.1). Cette différence était en moyenne de 7 % pour les parcelles 10N et 64N, contre 5 % pour la parcelle 100N (apprentissage) et 11 % pour les parcelles 10N et 64N, contre 5 % pour la parcelle 100N (test).

Tableau 7.1 : Précisions de la classification des parcelles fertilisées (apprentissage) (juillet - septembre)

Modèles de MLP	MLP3		MLP4	
Méthodes	ACP	ADS	ACP	ADS
Configuration	7-6-1 (250)	2-2-1 (100)	7-5-1(210)	2-2-1 (110)
10N	68	94	91	98
64N	63	85	88	95
100N	71	84	92	97
Moyenne (%)	67	88	90	97
Kappa (%)	51	82	85	95

Tableau 7.2 : Précisions de la classification des parcelles fertilisées (test) (juillet - septembre)

Modèles de MLP	MLP3		MLP4	
Méthodes	ACP	ADS	ACP	ADS
Configuration	7-6-1 (250)	2-2-1 (100)	7-5-1(210)	2-2-1 (110)
10N	65	93	89	98
64N	62	83	85	99
100N	73	86	91	96
Moyenne (%)	67	87	88	98
Kappa (%)	50	81	82	95




Figure 7.1 : Variation des taux de classification des parcelles fertilisées durant la phase de test des modèles MLP3 et MLP4

L'analyse de la précision globale et des coefficients K montre les limites de l'ACP par rapport à l'ADS. En effet, de l'ACP à l'ADS, le coefficient K passe de 50 % à 81 % lors du test du MLP3 et de 82 % à 95 % pour le MLP4. Le test Z montre que la différence entre ces valeurs est significative ($p < 0,05$) (Annexe 7D). Cela signifie que la détection des zones d'azote à l'aide des variables issues de l'ADS est de 81 % (MLP3) ou de 95 % (MLP4) meilleure par rapport à celle obtenue par allocation des pixels aux mêmes classes selon une méthode aléatoire, contre 50 % (MLP3) et 82 % (MLP4) pour le cas de l'ACP.

Contrairement à l'ACP, l'ADS prend en compte les variances inter et intra classes dont le rapport est maximisé, ce qui a pour avantage d'optimiser la séparabilité entre les parcelles d'azote. Steiner (1979) a également mis en évidence la supériorité de l'ADS sur l'ACP lors de la classification d'images aériennes en milieu agricole. Il a montré que les cinq premières CP (88 % de la variance totale de l'image) génèrent un taux de bonne classification de l'ordre de 73 %. Par contre, les 8 variables (sur 18) sélectionnées par l'ADS ont généré 92 % de pixels bien classifiés.

L'ACP ne semble donc pas être optimale en terme de séparabilité des parcelles d'azote relativement à l'ADS. Cependant, l'amélioration des résultats du modèle MLP4_{ACP} montre que des données auxiliaires comme les paramètres topographiques peuvent être très utiles pour maximiser l'information extraite par les CP. En fait, le degré de corrélation qui est le critère de base à partir duquel l'ACP extrait de nouvelles CP non corrélées, ne signifie pas nécessairement un chevauchement de l'information en terme de discrimination de classes (Steiner, 1979). Ainsi, deux variables peuvent être très corrélées et avoir un pouvoir discriminant faible lorsqu'elles sont utilisées séparément, alors que leur combinaison produit un taux de discrimination plus élevé.

Les statistiques qui sont ressorties de la classification des parcelles d'azote à l'aide de l'image du 21 juillet uniquement indiquent que la performance des IT était plus faible que celle des IV. Toutefois, l'ensemble des coefficients K était faible, particulièrement durant le test où K est respectivement de 57 % et 49 % pour le MLP1 et le MLP2, contre 64 % et 60 % en apprentissage (Tableaux 7.3 et 7.4).

Tableau 7.3 : Précisions de la classification des parcelles fertilisées (apprentissage) (juillet)

Modèles de MLP	MLP1	MLP2	MLP3	MLP4
Configurations	4-5-3	4-5-3	8-8-3	11-11-3
10N	84	78	92	100
64N	67	59	75	91
100N	76	84	82	95
Moyenne (%)	76	74	83	96
Kappa (%)	64	60	75	94

Tableau 7.4 : Précisions de la classification des parcelles fertilisées (test) (juillet)

Modèles de MLP	MLP1	MLP2	MLP3	MLP4
Configurations	4-5-3	4-5-3	8-8-3	11-11-3
10N	82	71	91	98
64N	59	55	73	90
100N	77	76	78	91
Moyenne (%)	71	66	81	93
Kappa (%)	57	49	72	90

Ces résultats montrent que pris séparément, les IV et IT captent difficilement l'ensemble du patron de variation des parcelles fertilisées en azote. Cependant, l'intégration de ces indices dans le MLP3 a fourni une plus grande séparabilité entre ces parcelles. La précision globale était respectivement de 83 % et 81 % pour l'apprentissage et le test du réseau avec des coefficients K de l'ordre de 75 % et 72 %. Le test Z montre que pris deux à deux, le coefficient K des modèles MLP1, MLP2 et MLP3 étaient différents ($p < 0,05$) (Annexe 7D). En d'autres termes, le modèle MLP basé sur la combinaison des indices spectraux et texturaux permet de discriminer effectivement le maïs en condition de déficit azoté (10N) du maïs en condition normale de croissance (100N). Une telle intégration d'indices permet de mettre à profit l'information fournie par chaque indice afin d'améliorer la détection de la différence de fertilisation à l'échelle du champ.

Bien que l'utilisation conjointe de l'information spectrale et texturale dans le modèle MLP3 ait amélioré la classification des parcelles fertilisées, la proportion de pixels non classifiés était encore élevée pour les zones 64N et 100N. Celle-ci était en moyenne de 16 % et 23 % pour les images de juillet-septembre et juillet respectivement. Dans le cas des classifications effectuées avec les intrants issus de l'ACP, le pourcentage moyen de pixels non classifiés est passé à 33 % pour les trois parcelles. Cela signifie que les seules données de télédétection n'ont pas suffi à bien identifier toutes les variations subtiles dans ces parcelles fertilisées en azote. D'où l'importance d'intégrer dans le MLP des données auxiliaires comme les paramètres topographiques.

L'intégration de la topographie dans le modèle MLP4 a permis de faire passer les coefficients K du test de 50 % à 82 % dans le cas de l'ACP et de 80 % à 95 % dans le cas de l'ADS (Tableaux 7.1 à 7.4 et Annexe 7D). Lorsqu'on a considéré l'image AISA du 21 juillet uniquement, le coefficient K est passé de 72 % (MLP3) à 90 % (MLP4), soit une augmentation de 28 %. La discrimination individuelle des parcelles d'azote a également été améliorée (Figure 7.2). La contribution des paramètres topographiques à la classification des zones d'azote provient du fait qu'ils jouent un rôle important dans la disponibilité des éléments minéraux de l'eau du sol et dans la définition du drainage du champ (Changere and Lal, 1997).




Figure 7.2 : Variation des taux de classification des parcelles fertilisées selon l'apport (MLP4) ou non (MLP3) de la topographie (juillet)




Figure 7.3 : Taux de classification des parcelles d'azote lors de la phase de test du MLP3 (juillet et juillet - septembre)

La variation du contenu en information des images en fonction de leur date d'acquisition a également été évaluée dans cette étude. Nous avons comparé la précision globale des modèles de juillet (MLP3_{juil} et MLP4_{juil}) à celle des deux images de juillet - septembre (MLP3_{juil-sept} et MLP4_{juil-sept}) dans le cas de l'ADS uniquement. Nous avons ainsi vérifié la possibilité de détection du stress en azote par une image acquise à la mi-saison.

Pour chacun des couples MLP3_{juil} - MLP3_{juil-sept} et MLP4_{juil} - MLP4_{juil-sept}, l'hypothèse alternative H_1 ($\mu_1 \neq \mu_2$) est acceptée selon les tests statistiques. Cela veut dire que les précisions globales fournies par ces modèles sont statistiquement différentes. Autrement dit, les modèles développés sur les deux images juillet-septembre sont plus performants que ceux développés sur l'image de juillet (Annexe 7D4). Les coefficients K (test) étaient respectivement de 72 % et 90 % pour l'image de juillet contre 81 % et 95 % pour l'ensemble des images combinées pour les modèles MLP3 et MLP4. Cela revient à une différence de 9 % et 5 % entre les couples de modèles MLP3 et MLP4 respectivement. Ainsi, même si l'image de septembre a un faible pouvoir de prédiction des rendements agricoles comme nous l'avons vu dans les chapitres précédents, elle a un contenu en information suffisant pour améliorer la performance du modèle MLP4.

Il a été montré à travers cette étude que le MLP a un très grand potentiel d'identification du patron de variation de la végétation de maïs lié au déficit azoté. La précision de la classification était assez élevée avec des coefficients K qui variaient entre 74 % et 95 % dans le cas de l'ADS. L'intégration de la topographie a permis de rehausser le contenu en information de CP, ce qui indique que les paramètres topographiques sont des facteurs discriminants potentiels pour les classes de végétation en condition de déficit azoté. Par conséquent, les programmes de gestion des rendements des cultures devraient dans la mesure du possible prendre en compte les effets combinés de ces paramètres. Ces résultats sont en accord avec ceux de Yang *et al.* (2000) qui ont développé un modèle de MLP pour distinguer de jeunes plants de maïs des mauvaises herbes à partir d'un indice de couleur. Ils ont obtenu des taux de classification de 80 % à 100 % pour le maïs et de 60 % à 80 % pour les mauvaises herbes.

7.4 Conclusion

Quatre modèles de MLP ont été testés dans le but de discriminer des parcelles de maïs traitées avec différentes doses d'azote. Les intrants de ces modèles étaient constitués par des variables spectrales, texturales et topographiques sélectionnées à partir de l'ACP et de l'ADS.

La contribution relative des indices spectraux et texturaux dans les modèles discriminants montre que le WDVl est un bon descripteur des effets du déficit en azote chez le maïs. Les trois autres indices de végétation (TSARVI, SAVI et NDVI) se sont révélés comme des indicateurs moyens de la différence de croissance végétale. Pour augmenter la capacité de détection du stress en azote, il serait pertinent d'utiliser également la méthode de la dérivée spectrale qui permet de mettre en évidence la dynamique de variation de la zone de transition rouge - PIR appelée *red edge*. Plusieurs études ont en effet montré que ce *red edge* est très corrélé aux teneurs en pigments foliaires, particulièrement la chlorophylle (Tarpley *et al.*, 2000; Moran *et al.*, 2000). L'utilisation de cette méthode requiert toutefois une image disposant d'un grand nombre de bandes spectrales, raison pour laquelle nous n'avons pas abordé la question de la dérivée spectrale dans notre travail.

Quant aux paramètres de texture de l'image, ils ont fourni une information complémentaire utile pour améliorer la discrimination des classes de végétation. Cependant, l'efficacité de l'ensemble de ces indicateurs est directement reliée à la période d'acquisition des images, en ce que l'information captée par celle-ci varie selon le stage de croissance de la culture considérée.

Bien que le MLP ait été développé et testé sur des données collectées uniquement sur trois parcelles d'un même traitement, cette approche a généré d'excellents résultats qui sont prometteurs dans le domaine agricole. Elle constitue une contribution à la problématique de la détection des stress végétaux. En effet, le fait d'intégrer des images de télédétection lui permet de remédier à la limite des méthodes actuelles, entre autre, les petits espaces échantillonnés et le manque de la représentativité des échantillons. L'avantage d'une telle

approche est qu'elle est facilement applicable à toutes les cultures et pour différents types de stress végétaux. Comme le MLP s'ajuste très bien à des données non linéaires, cette approche n'a pas de contrainte au niveau de la distribution et du nombre des variables d'entrée. Cette approche de détection du stress en azote peut être combinée avec un système d'informations géographiques pour mettre en place un outil de surveillance des conditions de croissance des cultures et d'aide à la décision en milieu agricole. Dans un programme futuriste, cet outil pourrait être relié à un système automatique d'irrigation et d'application d'azote et l'ensemble fonctionnerait d'une façon autonome en temps réel pour simplifier la tâche des agriculteurs. Ainsi, les images acquises régulièrement sont stockées dans une base de données, traitées et intégrées dans le MLP pour la détection en temps réel des zones présentant un problème quelconque de croissance. À partir des critères de décision dont dispose le SIG, la nature du stress végétal est d'abord déterminée, puis confirmée. L'intensité de ce stress est ensuite évaluée sur une échelle donnée et les quantités adéquates d'éléments nutritifs, ainsi que leur durée d'application sont calculés avant de déclencher le système automatique d'irrigation ou de fertilisation dans le secteur à problème.

Chapitre VIII

Contributions et recommandations

La présente thèse visait à évaluer le potentiel du réseau MLP comme outil de prédiction des rendements agricoles et du déficit en azote. Ce réseau a utilisé comme intrants des indicateurs extraits d'images AISA et des photographies aériennes. Ces derniers ont été associés à des paramètres topographiques afin de tenir compte de la contribution potentielle du relief dans la croissance végétale. Nous avons atteint les objectifs fixés et validé nos hypothèses de recherche. Il faut mentionner cependant que compte tenu du nombre limité des données à notre disposition (deux à trois images par culture et pour une seule saison agricole), plusieurs des conclusions énoncées ci-dessous devraient être vérifiées sur d'autres ensembles de données couvrant plusieurs dates.

Le réseau MLP a montré à travers cette recherche sa capacité à modéliser les rendements agricoles à partir d'indicateurs extraits d'images aéroportées. Il possède également un grand potentiel d'identification du patron de variation de la végétation de maïs lié au déficit azoté. Cette performance provient principalement de sa structure interne non linéaire qui lui permet d'évaluer différentes fonctions avec une bonne précision. Nos résultats mettent en évidence la possibilité d'utiliser le MLP comme outil de diagnostic pour fournir une assistance directe aux producteurs agricoles pendant la saison afin d'identifier et de corriger les problèmes de croissances des cultures avant que ces derniers n'affectent la production finale. Cet outil peut également faire office d'un système de

gestion pour l'application à taux variables de fertilisants à l'échelle du champ. Toutefois, bien que le MLP offre de nombreux avantages, ce travail a montré que la précision de ses résultats dépend de la qualité des données. Par conséquent, l'algorithme DÉFIS que nous avons développé constitue un outil complémentaire du MLP dans des applications qui intègrent les rendements agricoles. Les corrections effectuées par DÉFIS mettent en évidence son efficacité et sa pertinence pour le traitement et l'utilisation des données issues des capteurs de rendements.

La variabilité spatiale des rendements du maïs et du soya a été captée par les indicateurs spectraux et texturaux sélectionnés. Leur combinaison a permis d'expliquer jusqu'à 68 % de la variance totale du maïs et 24 % pour le soya. Le potentiel des indices spectraux, et à un degré moindre, les indices de texture, à discriminer le déficit en azote n'a pas été affecté par l'aspect temporel des images, mais plutôt par la variance inter-parcelle. Le déficit en azote ayant entraîné une différence très nette au niveau du LAI entre les traitements, le contenu en information de l'image de fin de saison s'est avéré pertinent pour identifier les parcelles d'azote.

Parmi les indices utilisés, le WDVI, le TSARVI et le SMA ont été particulièrement sensibles aux variations de LAI dues à la différence de fertilisation en azote. Les effets de celle-ci ont d'ailleurs été plus marqués dans le PIR que dans le visible, ce qui signifie que la biomasse végétale a réagi clairement aux variations des teneurs d'azote foliaire.

Bien qu'ayant amélioré faiblement les résultats du MLP, les paramètres topographiques demeurent des variables importantes en agriculture et leur contribution devrait toujours être évaluée dans les modèles agricoles.

Enfin, des deux méthodes de réduction de la dimension des intrants du réseau, l'ADS a généré les plus faibles erreurs RMS pour tous les cas d'application comparativement à l'ACP. La supériorité de l'ADS sur l'ACP a été plus marquée dans la configuration du MLP qui combine les paramètres spectraux et texturaux. Cela montre également que l'utilisation du MLP demande qu'on prête une attention particulière à la qualité et à la taille des intrants.

Les principales contributions de cette thèse peuvent être résumées comme suit :

1. **DÉFIS** a été développé pour corriger et traiter les données de rendements agricoles. Cet algorithme propose une nouvelle méthode de détermination adaptative des délais des rendements pour chaque parcours de la moissonneuse. Cette démarche améliore la qualité des données, car elle évite d'utiliser des délais trop élevés ou trop bas. **DÉFIS** va grandement faciliter le travail des utilisateurs de ce type de données qui étaient obligés de faire manuellement les corrections à l'aide de logiciels comme Excel ou Access. Ces logiciels sont souvent limités par le nombre de points du fichier d'entrée contrairement à **DÉFIS**. Le chiffrier Microsoft Excel par exemple, ne peut traiter qu'un maximum de 65535 points, alors que le fichier brut des rendements du maïs que nous avons utilisé contenait environ 75 000 points. Ce programme peut toutefois être amélioré afin de s'adapter aux données issues de la majorité des capteurs de rendements agricoles.
2. Nous proposons un modèle simplifié (qui utilise peu de variables) de prédiction des rendements agricoles à l'aide du réseau MLP. Ce modèle utilise essentiellement des indices spectraux et texturaux et il offre la possibilité d'intégrer des données auxiliaires. C'est un outil efficace de gestion de la production agricole dont le fonctionnement ne dépend ni de la distribution des données, ni de paramètres spécifiques reliés au site ou à la culture étudiée.
3. Une variante de ce modèle est également proposée pour détecter les problèmes de croissance liés aux stress végétaux, en particulier le déficit en azote. Ce modèle présente l'avantage d'intégrer tous les effets des stress végétaux par l'utilisation des images de télédétection. Cette composante spatiale augmente la précision du modèle, car le nombre d'échantillons traités est plus représentatif contrairement aux méthodes classiques.

Comme le mentionne Boisvert (1993), « Chaque nouvelle réponse ouvre la porte à une nouvelle question. » Vu l'intérêt grandissant pour l'application des nouvelles

technologies pour la prédiction précoce des conditions de croissance des cultures, il serait pertinent de porter un regard sur un certain nombre de questions : comment quantifier l'impact des erreurs de la carte des rendements agricoles sur la variabilité spatiale observée dans le champ ? Quelle est l'influence de chacune de ces erreurs sur la performance des techniques de l'intelligence artificielle comme le MLP ? Quel sera le niveau de précision d'un MLP développé à partir d'une fusion d'images optiques et radars ?

Références bibliographiques

Abuelgasim, A., Gopal, S. and Strahler, A. (1998) Forward and inverse modeling of canopy directional reflectance using a neural network. *International Journal of Remote Sensing*, vol. 19, p. 453-471.

Allen, W. and Richardson, J. (1968) Interaction of light with a plant canopy. *Journal of the Optical Society of America*, vol. 58 (8), p. 1023-1028.

Andrieu, B., Kiriakos, S. and Jaggard, K. (1992) Estimation de la concentration en chlorophylles de feuilles par la mesure de leur réflectance ou par analyse numérique de photographies prises au laboratoire. *Agronomie*, vol. 12, p. 477-485.

Aparicio, N., Villegas, D., Casadesus, J., Araus, J. and Royo, C. (2000) Spectral vegetation indices as non-destructive tools for determining durum wheat yield. *Agronomy Journal*, vol. 92 (1), p. 83-91.

Atkinson, P. and Tatnall, A. (1997) Neural networks in remote sensing. *International Journal of Remote Sensing*, vol. 18(4), p. 699-709.

Bannari, A., He D.C., Morin, D. et Anys, H. (1998) Analyse de l'apport de deux indices de végétation à la classification dans les milieux hétérogènes. *Journal Canadien de Télédétection*, vol. 24 (3), p.233-239.

Baillargeon, G. (1984) Méthodes statistiques : méthodes d'analyses et de régression linéaire simple et régression multiple avec applications dans différents secteurs de l'entreprise. Les éditions SMG, vol. 2, 244 p.

Baret, F. (1995) Use of spectral reflectance variations to retrieve canopy biophysical characteristics. *Advances in Environmental Remote Sensing*, p. 33-51.

Batchelor, W., Yang, X. and Tschanz, A. (1997) Development of a Neural Network for Soybean Rust Epidemics. *Transactions of the American Society of Agriculture Engineers*, vol. 40 (1) p. 247-252.

Bausch, W. (1993) Soil background effects on reflectance-based crop coefficients for corn. *Remote Sensing of Environment*, vol. 46 (2), p. 213-222.

Bausch, W. and Duke, H. (1996) Remote sensing of plant nitrogen status in corn. *American Society of Agricultural Engineers*, vol. 39 (5), p. 1869-1875.

Benediktsson, J., Swain, P. and Ersoy, O. (1990) Neural Network Approaches Versus Statistical Methods in Classification of Multisource Remote Sensing Data. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 28 (4), p. 540-551.

Benediktsson, J. and Swain, P. (1993) Conjugate-gradient neural networks in classification of multisource and very-high-dimensional remote sensing data. *International Journal of Remote Sensing*, vol. 18 (4), p. 699-709.

Birrel, S. and Sudduth, K. (1996) Comparaison of sensors and techniques for crop yield mapping. *Computers and Electronics in Agriculture*, vol. 4, p. 215 – 233.

Bishop, C. (1995) Neural network for pattern recognition. Clarendon press, Oxford, 482p

Blackmer, T. (1995) Remote sensing techniques to detect nitrogen stress in corn. Ph D. Dissertation. University of Nebraska, Lincoln.

Blackmer, T. and Shaepers S. (1996) Aerial photography to detect nitrogen stress in corn. *Journal of Plant Physiology*, vol. 148, p. 440-444.

Blackmore, S. and Marshall C. (1996) Yield mapping: errors and algorithms. 3th *International Conference on Precision Agriculture*, June 23-26, 1996, Minneapolis, USA

Boisvert, J. (1993) Modélisation du signal radar en milieu stratifié et évaluation de techniques de mesure de l'humidité du sol. Thèse de doctorat, Université de Sherbrooke, QC, Canada, 160 p.

Bonn, F. et Rochon, G. (1992) Précis de télédétection : principes et méthodes, vol. 1, Presses de l'Université du Québec, Canada, 485 p.

Bouman, B. (1991) The linking of crop growth models and multi-sensor remote sensing data. *Proceedings of the 5th International Colloquium – Physical Measurements and Signatures in Remote Sensing*, Courchevel, France, 14-18 January 1991, p. 583-588.

Bouman, B., van Kasteren and Uenk, D. (1992) Standard relations to estimate ground cover and LAI of agricultural crops from reflectance measurements. *European Journal of Agronomy*, vol. 1(4), p. 249-262.

Bouman, B. (1995) Crop modelling and remote sensing for yield prediction. *Netherlands Journal of Agricultural Science*, vol. 43, p. 143-161.

Bourret, P., Reggia, J. et Samuelides, M (1991) Réseaux neuronaux: une approche connexionniste de l'intelligence artificielle. Édition Teknea, 269 p.

Cambardella, C., Colvin T., Karlen, D., Logsdon, S., Berry, E. and Radke, J. (1996) Soil property contributions to yield variations pattern, Ruth R. and Larson W. *Proceedings of the third international conference on precision agriculture*, Madison, WI, p. 417-424.

Cassel, D., Wendroth, O. and Nieldson, D. (2000) Assessing spatial variability in an agricultural experiment station field: opportunities rinsing from spatial dependence. *Agronomy Journal*, vol. 92 (4), p. 706-714.

Changere, A. and Lal, R. (1997) Slope position and erosional effects on soil properties and corn production on a Miamian soil in central Ohio. *Journal of Sustainable Agriculture*, vol. 11, p. 5-21.

Charalambous, C. (1992) Conjugate gradient algorithm for efficient training of artificial neural networks. *IEEE Proceedings*, vol. 139 (3), p. 301-310.

Clevers, J. (1988) The derivation of simplified reflectance model for the estimation of leaf area index. *Remote Sensing of Environment*, vol. 25, p. 53-69.

Clevers, J. (1997) A simplified approach for yield prediction of sugar beet based optical remote sensing data. *Remote Sensing of Environment*, vol. 61, p. 221-228.

Clevers, J., Bucker, C, van Leuken, H. and Bouman, B. (1994) A framework for monitoring crop growth by combining directional and spectral remote sensing information. *Remote Sensing of Environment*, vol. 50 (2), p. 161-170.

Cohen, J. (1960) A coefficient of agreement for nominal scales. *Educational and Psychological measurement*, vol. 20 (1), p. 37-46.

Collins, J. and Woodcock, C. (1995) Change detection using the Gramm-Schmidt transformation applied to mapping forest mortality. *Remote Sensing of Environment*, vol. 50, p. 267-279.

Congalton, R. and Mead, R. (1983) A quantitative method to test for consistency and correctness in photointerpretation. *Photogrammetric Engineering and Remote Sensing*, vol. 49 (1), p. 69-74.

Crafts-Brander, S., Below F., Harper J. and Hageman R. (1984) Differential senescence of maize hybrids following ear removal. I. Whole plant. *Plant Physiology*, vol. 74, p. 360-367.

Delecolle, R., Mass, S., Guerif, M. and Baret, F. (1992) Remote sensing and crop production models: present trends. *ISPRS Journal of Photogrammetry Remote Sensing*, vol. 47 (2), p. 145-161.

Del Frate, F., Ferrazzoli, P. and Schiavon, G. (1999) Retrieving agricultural variables by microwave radiometry using a neural network algorithm trained by a physical model. *International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 4, p. 2134-2136..

Elizondo, D., Clendon, R. and Hoogenboom (1994) Neural network models for prediction flowering and physiological maturity of soybean. *Transactions of the American Society of Agriculture Engineers*, vol. 37 (3) p. 981-988.

ESRI, Inc. (1995a) ArcView spatial analyst, Environmental systems research institutes Inc., Redlands, California, 147 p.

ESRI, Inc. (1995b) Understanding GIS, the ARC/INFO method. Environmental systems research institute Inc., Redlands, California.

Fernandez, S., Vidal D., Simon, E. and Solè-Sugranes, L. (1994) Radiometric characteristics of *Triticum aestivum* cv. astral under water and nitrogen stress. *International Journal of Remote Sensing*, vol. 15, p. 1459-1470.

Filella I, Serrano, L., Serra, J. and Penuelas, J. (1995) Evaluating wheat nitrogen status with canopy reflectance indices and discriminant analysis. *Crop Science*, vol. 35, p. 1400-1405.

Fung, A. (1994) Microwave Scattering and Emission Models and Their Applications. Artech House, Norwood, MA, 573 p.

Gilabert, M., Gandia, S. and Melia, J. (1996) Analyses of spectral-biophysical relationships for a corn canopy. *Remote Sensing Reviews*, vol. 55, p. 11-20.

Gong, P., Wang, D. and Liang, S. (1999) Inverting a canopy reflectance model using a neural network. *International Journal of Remote Sensing*, vol. 20 (1), p. 111-122.

Gopal, S. and Woodcock, C. (1996) Remote sensing of forest change using artificial neural networks. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 34, p. 398-404.

Hair, J., Anderson, R., Tatham, R. and Black, W. (1998) Multivariate data analysis, Fifth edition, 730 p.

Han, S., Schneider, M., Rawlins, S. and Evans, R. (1996) A bitmap method for determining effective combine cut width in yield mapping. *Transactions of the American Society of Agriculture Engineers*, vol. 40 (2), p. 485-490.

Haralick, R. and Shanmugan, K. (1973) Textural Features for Image Classification. *IEEE Transactions on Systems, Man and Cybernetics*, vol. 3 (6), p. 610-621.

Haralick, R. (1979) Statistical and Structural Approaches to Texture. *Proceedings of the IEEE*, vol. 67 (5), 5, May, p. 786-804.

Holben, B. and Fraser, R (1984) Red and near-red sensor response to off-nadir viewing. *International Journal of Remote Sensing*, vol. 5, p. 145-160.

Huete, A. and Jackson, R. (1988) Suitability of spectral indices for evaluating vegetation characteristics on arid rangelands. *Remote Sensing of Environment*, vol. 23, p. 213-232.

Jensen, J. (1996) Introductory Digital Processing. A Remote Sensing Perspective. 2nd Edition. Prentice Hall Series in Geographic Information Science. 316 p.

Jin, Y-Q and Liu, C. (1997) Biomass retrieval from high-dimensional active/passive remote sensing data by using artificial neural networks. *International Journal of Remote Sensing*, vol. 18 (4), p. 971-979.

Johansson, E., Dowla, F. and Goodman, D. (1992) Back-propagation learning for multiplayer feed-forward neural networks using the conjugate gradient method. *Int. Neural Systems*, vol. 2 (4) p. 1-10.

Johnson, L. and Billow C. (1996) Spectrometric estimation of total nitrogen concentration in Douglas-fir foliage. *International Journal of Remote Sensing*, vol. 17 (3), p. 489-500.

Kaiser, H. (1960) The application of electronic computers to factor analysis. *Educational and psychological measurements*, vol. 20, p141-151.

Kavzoglu, T. and Paul M. (2000) Using feature selection techniques to produce smaller neural networks with better generalization capabilities. *International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 7, July 24-28, p. 3069-3071.

Keiner, L. and Brown, W. (1999) Estimating oceanic chlorophyll concentrations with neural networks. *International Journal of Remote Sensing*, vol. 20 (1), p. 189-194.

Kenneth, J., James W. and Nigel B. (1996) Potential uses and limitations of crop models. *Agronomy Journal*, vol. 88, p. 704-716.

Kimes, D., Nelson, R., Manry, M. and Fung, A. (1998) Attributes of neural networks for extracting continuous vegetation variables from optical and radar measurements. *International Journal of Remote Sensing*, vol. 19 (14), p. 2639-2663.

Kleinbaum, D., Kupper, L. and Muller, K. (1988) Applied regression analysis and other multivariate method. 2nd edition, 718 p.

Koch, P. (1994) Artificial neural network configuration for predicting corn yield as a function of water regime. Ph. D. thesis, University of Nebraska, Lincoln, 133 p.

Kravchenko, N. and Bullock, D. (2000) Correlation of corn and soybean grain yield with topography and soil properties. *Agronomy Journal*, vol. 92 (1), p. 75-82.

Kuusk, A. (1994) Multispectral canopy reflectance model. *Remote Sensing of Environment*, vol. 50, p. 75-82.

Lamb, J., Anderson, J., Maizer, L., Vetch, A., Dowdy, R., Onken, D. and Ault, K. (1995) Perils of monitoring grain yield on-the-go. *Soil Specific Management for Agricultural Systems*, Madison, USA, p. 87-90.

Li, X. and Strahler, A. (1992) Geometric optical bidirectional reflectance modeling of the discrete crown vegetation canopy: effects of crown shape and mutual shadowing. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 30, p. 276-292.

Lillesand, T. and Kiefer R. (2000) Remote sensing and image interpretation. 4th ed, New York. J. Wiley & Sons, 724 p.

Lippmann, R. (1987) An introduction to computing with neural nets. *IEEE ASSP Magazine*, vol. 4, p. 4-22.

Luenberger, D. (1984) Linear and nonlinear programming. Reading, MA : Addison-Wesley Publishing Company, Inc.

Makisara, K., Meinander, M., Rantasuo, M., Okkonen, M and Aikio, M. (1993) Airborne imaging spectrometer for applications (AISA). *International Geoscience and Remote Sensing Symposium*, (Tokyo, Japan), p. 479-481.

McConkey, B., Ulrich, D. and Dyck, F. (1997) Slope position and subsoiling effects on soil water and spring wheat yield. *Canadian Journal of Soil Science*, vol. 77, p. 83-90.

Moran, A., Mitchell, A., Goodmansson, G., Stockburger, K. (2000) Differentiation among effects of nitrogen fertilization treatments on conifer seedlings by foliar reflectance: A comparison of methods. *Tree Physiology*, vol. 20 (16), p. 1113-1120.

Montour, L. (1997) Le fonctionnement et les applications à la ferme du capteur de rendement et du système de positionnement par satellite. Actes du colloque - Nouvelles technologies en agriculture. Campus Fort St-Jean, p. 29-34.

Moore, M. (1997) An investigation into the accuracy of yield maps and their subsequent use in crop management. Ph D. thesis, Department of agriculture and biosystems engineering, Silsoe College, Cranfield University, UK, 530 p.

Murase, H., Honami, N. and Nishiura, Y. (1995) A neural network estimation technique for plant water status using the textural features of pictorial data of plant canopy. *Acta Horticulturae*, vol. 399, p. 255-262.

Murphy, D., Schnug, P. and Haneklaus S. (1995) Yield mapping – a guide to improved techniques and strategies, In Roberts, P. C., R. H. and Larson, W. E. (ed). *Soil Specific Crop Management, American Society of Agronomy*, Madison, USA, p. 33-47.

Paola, J. and Schowengerdt, R. (1995) A review and analysis of back-propagation neural networks for classification of remotely sensed multispectral imagery. *International Journal of Remote Sensing*, vol. 16 (16), p. 3059-3067.

Pattey, E., Strachan, I., Boisvert, J., Desjardins, R. and McLaughlin, N. (2001) Detecting effects of nitrogen rate and weather on corn growth using micrometeorological and hyperspectral reflectance measurements. *Agricultural and Forest Meteorology*, vol. 2945, p. 1-15.

Peddle, D. and Franklin, S. (1991) Image texture processing and data integration for surface pattern discrimination. *Photogrammetric Engineering and Remote Sensing*, vol. 57 (4), p.413-420.

Pierce, J. (1997) Yield mapping: measuring harvests can improve crop management. *Resource*, p. 9-10.

Pierce, L. and Ulaby, F. (1994). Application of artificial neural network in canopy scattering inversion. *International Journal of Remote Sensing*, vol. 15, p. 3263-3270.

Piekielek, W. and Fox H. (1992) Use of chlorophyll meter to predict sidedress nitrogen requirements for maize. *Agronomy Journal*, vol. 84 (1), p. 59-65.

Polatin, P., Sarabandi, K. and Ulaby, F. (1994) An iterative inversion algorithm with application to the polarimetric radar response of vegetation canopies. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 32, p. 62-71.

Priya, S. and Shibasaki, P. (2001) National spatial crop yield simulation using GIS-based crop production model. *Ecological modelling*, vol. 135, p. 113-129.

Privette, J., Myneni, R. and Emery, W. (1996) Optimal sampling conditions for estimating grassland parameters via reflectance model inversions. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 34, p. 272-284.

Rands, M. (1995) The development of an expert filter to improve the quality of yield mapping data. MSc. Thesis, Silsoe College, Cranfield University.

Redondo, M., Fernandez, E. and Carlos, H. (1999) Comparison among feature selection methods based on trained networks. *Neural Networks for Signal, Processing - Proceedings of the IEEE Workshop* Aug 23-25 p. 205-214.

Rosario, R. and Nazif, T. (1992) A rapid multiplayer training algorithm. *International Joint Conf. on Neural Network*, vol. 1, p. 824-829.

Ruan, R., Ning, S., Song, A., Ning, A., Jones, R. and Chen, P. (1998) Estimation of Fusarium Scab in Wheat Using Machine Vision and a Neural Network. *Cereal Chemistry*, vol. 75 (4), p. 455-459.

Rudorff, B. and Batista, G. (1991) Wheat yield estimation at the farm level using TM Landsat and agrometeorological data. *International Journal of Remote Sensing*, vol. 12 (12), p. 2477-2484.

Rumelhart, D., Hinton, G. and Williams, R. (1986) Learning internal representations by error propagation. In parallel distributed processing: explorations in the microstructure of cognition. Volume 1: Foundations. The MIT Press, Cambridge, MA, p. 318-362.

Satalino, G., Mattia, F., Le Toan, T., Davidson, M. and Borgeaud, M. (1999) The potential of multi angle C-band SAR data Soil Moisture retrieval. *International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 2, p. 1121-1123.

Sérélé, C. (1996) Processus d'écoulement et de transport dans les stériles miniers non saturés : essais d'infiltration sur une colonne en laboratoire. Mémoire de maîtrise, Université Laval, QC, Canada, 104 p.

Sérélé, C., Boisvert, J., Q., Hugh Gwyn Q., Pattey, E. and Daoust, D. (2000) Corn yield prediction with artificial neural network trained using airborne remote sensing and topographic data. *International Geoscience and Remote Sensing Symposium (IGARSS)* vol. 1, Jul 24-28, p. 384-386.

Shearer, S., Burks, T., Thomson, J., Mueller, T., Fulton, J., Higgins, S. *et al.* (1998). Yield prediction using a neural network classifier trained using soil landscape features and soil fertility data. *Transaction of American Society of Agricultural Engineers, Paper No. 993042*.

Schepers, J., Francis, D., Vigil, M and Below, E. (1992) Comparison of corn leaf nitrogen concentration and chlorophyll meter readings. *Communications in Soil Science Plant Analysis*, vol. 23 (17), p. 2173-2187.

Simpson, G. (1998) Crop yield prediction using a CMAC neural network. *Image and signal processing for remote sensing - Proceedings of the remote sensing*, Rome Italy, Sept. 26-30, vol. 2315, p.160-171.

Singh, A. (1986) Change detection in the tropical forest environment of northeastern India using Landsat. *Remote Sensing and tropical land Management* (Eden, M.J. and Parry, J.T. eds.), John Wiley and Son, Chichester, p. 237-254.

Skidmore, A., Turner, B., Brinkhof, W. and Knowles, E. (1997) Performance of a neural network: mapping forests using GIS and remotely sensed data. *Photogrammetric Engineering and Remote Sensing*, vol. 63 (5), p. 501-514.

Smart van der (1994) Minimization methods for training feed-forward neural networks. *Neural networks*, vol. 7 (1) p. 1-11.

Smith, J. (1993) LAI inversion using a back-propagation neural network trained with a multiple scattering model. *IEEE Transactions on Geoscience and Remote Sensing*, vol. 31, p. 1102-1106.

Spitters, C., van Keulen, T. and van Kraailingen D. (1989) A simple and universal crop growth simulator: SUCROS87, in *Simulation and Systems Management in Crop Protection*, Simulation Monographs 32, Pudoc, Wageningen, p. 147-181.

Stafford, J., Ambler, B., Lark, R. and Catt, J. (1996) Mapping and interpreting the yield variation in cereal crops. *Computers and Electronics in Agriculture*, vol. 14, p. 101-119.

StatSoft Inc. (1998) Statistica neural networks. Version 3.0 , 311 p.

StatSoft Inc. (1996) Statistica user guide networks. Version 5.1, vol. 1, 2, 3 and 4.

Stanhill, G., Kalkofi, V., Fuchs, M. and Kagan, Y. (1972) The effects of fertilizer applications on solar reflectance from a wheat crop. *Journal of Agricultural Resources*, vol. 22, p. 109-118.

Steiner, D. (1979) Computer processing and classification of multivariate information from remote sensing imagery. A review of methodology as applied to a sample of agricultural crops. *Annual Meeting of the American Society of Photogrammetry*. Washington D.C., p. 895-907.

Sudduth, K., Fraisse, C., Drummond, S. and Kitchen, N. (1996) Analysis of spatial factors influencing crop yield. In P.C. Roberts, Ruth R. and Larson W. (eds). *Proceedings of the third international conference on precision agriculture*, ASA, CSSA, SSSA, Inc., Madison, WI, p. 129-140.

Sudduth, K., Fraisse, C., Drummond, S. and Kitchen, N. (1998) Integrating spatial data collection, modeling and analysis for precision agriculture. *First international conference on geospatial information in agriculture and forestry*, Lake Buena Vista, Florida, 1-3 July 1998, Vol. 2 p. 166-173.

Tarassenko L. (1998) *A Guide to Neural Computing Applications*. New York- Toronto, Arnold, 139 p.

Tarpley, L. Reddy, K., Sassenrath-Cole, Gretchen, F. (2000) Reflectance Indices with Precision and Accuracy in Predicting Cotton Leaf Nitrogen Concentration. *Crop Science*, vol. 40 (6), p. 1814-1819.

Thai, C. and Shewfelt, R. (1991) Modeling sensory color quality of tomato and each : neural network and statistical regression. *Transactions of the American Society of Agriculture Engineers*. vol. 34 (3), p. 950-955.

Thorton, P. (1991) Application of crop simulation models in agricultural research and developpement in the tropics and subtropics. International Fertilizer Development Center, Muscle Sholad, AL (Paper series P-15).

Thylén, L., Donal P. and Murphy L. (1996) The control of errors in momentary yield data from combine harvesters. *Journal of Agricultural Engineers Resources*, vol. 63, p. 271-278.

Timlin, D., Pachepsky, Y., Snyder, V. and Bryant, R. (1998) Spatial and temporal variability of corn grain yield on hillslope. *Soil Science Society of American Journal*, vol. 62, p. 764-773.

Toner, M., Anderson, J and Lamb, J. (1997) Assessing corn yield and nitrogen uptake variability with digitized aerial infrared. *Photogrammetric Engineering and Remote Sensing*, vol. 63 (3), p. 299-306.

Törmä, M. (2000) The extraction of tree species information of forest stands using satellite images. *International Geoscience and Remote Sensing Symposium (IGARSS)*. July 28, Hawaii, USA.

Tsuji, G. and Bala, S. (1994) DSSAT version 3.0 DSSAT approach to input management. University of Hawaii, USA.

Uhrig, J., Engel, B. and Baker, W. (1992) An application of neural networks: predicting corn yields. *Computers in agricultural extension programs. Proceedings of the 4th International Conference, ASAE*, St-Joseph, Mich.

Ulaby, F., Sarabandi K., McDopnald M. and Dobson M. (1990) Michigan microwave canopy scattering model (MIMICS). *International Journal of Remote Sensing*, vol. 11, p. 1123-1253.

Vansichen, R. and De Baerdemaeker J. (1991) Continuous wheat measurement on a combine, In *Proceedings of Automated Agricultural for the 21st Century*, p. 346-355. Chicago, Ill, USA.

Verhoef, W. (1984) Light scattering by leaf layers with application to canopy reflectance. *Remote Sensing of Environment*, vol. 16 (2), p. 125-141.

Vouillot, M., Huet, P. and Boissard, P. (1998) early detection of N deficiency in a wheat crop using physiological and radiometric methods. *Agronomie*, vol. 18, p. 117-130.

Wang, Y. and Dong, D. (1997) Retrieving forest stand parameters from SAR backscatter data using a neural network trained by a canopy backscatter model. *International Journal of Remote Sensing*, vol. 18, p. 981-989.

Wayne, N. (1986) An introduction to digital image processing. Prentice-Hall International, 215 p.

Webster R. (1985) Quantitative spatial analysis of soil in the field. *Advances in Soil Science*, vol. 3., p. 1-70.

Williams, J., Jones, C., Kiniry, J. and Spanel, D. (1989) The EPIC crop growth model. *Transactions of the American Society of Agriculture Engineers*, vol. 32, p. 497-511.

Willis, P., Carter, P. and Johannsen, C. (1999) assessing yield parameters by remote sensing techniques. *Proceedings of the Fourth International Conference on Precision Agriculture*, Madison, USA, p. 1465-1473.

Wolfe, D. (1984) Water and nitrogen effects on leaf senescence in maize (*Zea mays* L.), Ph. D. dissertation, Univ. of California, Davis (Diss. Abst. 85-07341).

Woods, C., Reeves, W., Duffield, R. and Edmisten, L. (1992) Field chlorophyll measurements for evaluation of corn nitrogen status. *Journal of Plant Nutrition*, vol. 15 (4), p. 487-500.

Wu, W. and Massart, D. (1996) Artificial neural networks in classification of NIR spectral data: Selection of the input. *Chemometrics and Intelligent Laboratory Systems*, vol. 35, p. 127-135.

Xianyun, L., Smith, G., Askne, J. and Fransson, J. (2000) Biomass retrieval for boreal forest using electromagnetic scattering model and neural networks. *International Geoscience and Remote Sensing Symposium (IGARSS)*, vol. 1 Jul 24-28, p. 414-416.

Yang, C., Prasher, S., Sreekanth, S., Patni, N. and Masse, L. (1996) An artificial neural network model for simulating pesticide concentrations in soil. *Transactions of the American Society of Agricultural Engineers*, vol. 40 (5), p.1285-1294.

Yang, C., Anderson, G. and Everitt, J. (1998) A view from above: characterizing plant growth with aerial photography. *GPS world*, vol. 9 (4), p. 34-37.

Yang, C., Prasher, S., Sreekanth, S., Landry, J., Ramaswamy, H. *et al.* (2000) Application of artificial neural network in image recognition and classification of crop and weeds. *Canadian Agricultural Engineering*, vol. 42 (3), p.147-152.

Zhang, M., Hendley, P. and Grost, D. (1999) Corn and soybean yield indicators using remotely sensed vegetation index. *Proceedings of the Fourth International Conference on Precision Agriculture*, Madison, USA, p. 1473-1481.

Zhuang, X. and Engel, B. (1990) Neural networks for application in agriculture. *Transactions of the American Society of Agriculture Engineers* paper No. 90-7024. St-Joseph, Mich. : ASAE.

Zurada, J. (1996) Introduction to artificial neural systems. PWS Publishing Company, 683 p.

Annexe 3A : Statistiques descriptives des propriétés physico-chimiques du sol (maïs)

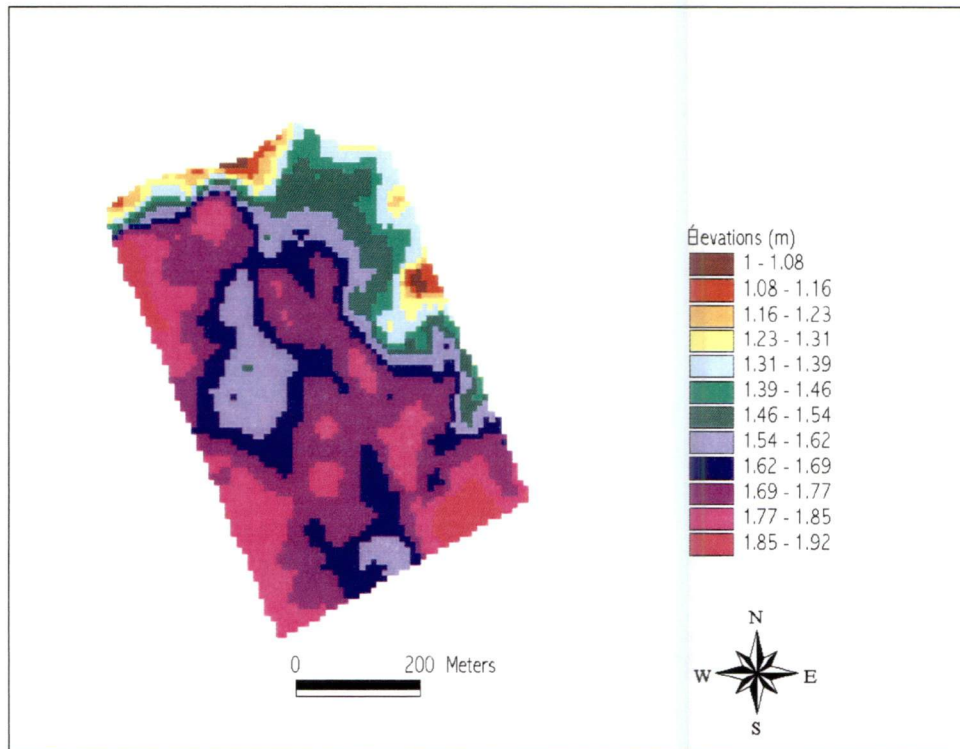
	Moyenne	Minimum	Maximum	Range	Écart type	CV	p
Élévation	1,65	1,03	1,90	0,87	0,25	0,15	0,000
pH	6,45	6,00	6,87	0,88	0,17	0,03	3,93e-06
P	35,38	21,36	64,59	43,23	9,36	0,26	2,08e-25
K	121,13	93,39	156,27	62,88	14,76	0,12	1,47e-17
MO	2,43	1,83	2,96	1,13	0,26	0,11	4,91 ^e -11
Mg	519,65	330,14	600,80	270,66	56,47	0,11	0,0000
CEC	16,78	9,43	20,06	10,63	2,38	0,14	0,0000
Ca	2102,23	1099,93	2781,85	1681,93	378,56	0,18	5,60e-27

Annexe 3B1 : Statistiques descriptives des propriétés physico-chimiques du sol (soya)

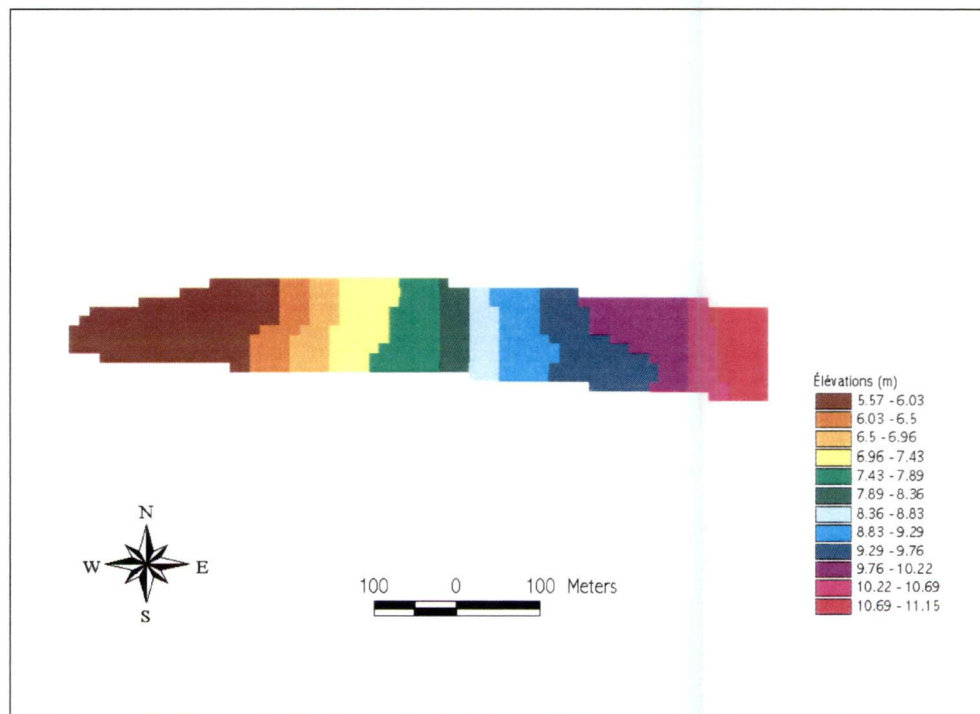
	Moyenne	Minimum	Maximum	Range	Écart type	CV	p
Élévation	8,21	5,58	11,11	5,53	1,72	0,21	6,96e-15
pH	6,09	5,15	7,34	2,19	0,61	0,10	2,33e-20
P	175,01	110,06	582,56	472,50	42,30	0,24	0,000
K	303,65	223,25	455,62	232,37	49,10	0,16	1,17e-23
MO	4,87	3,38	8,33	4,95	0,89	0,18	0,0000
Mg	638,99	218,13	1193,83	975,70	194,62	0,30	0,013
CEC	22,27	18,24	26,04	7,80	1,78	0,08	4,95e-06
Ca	5722,51	3439,70	9397,07	5957,37	1153,16	0,20	1,24e-15

Annexe 3B2 : Mesures d'indices foliaires (LAI) dans le champ de maïs - 1998

Dates	Jours Juliens	10N LAI	Dates	Jours Juliens	64N LAI	Dates	Jours Juliens	100N LAI
23-mai	144	0	23-mai	144	0	23-mai	144	0
22-juin	174	0,296	22-juin	174	0,381	22-juin	174	0,643
28-juin	180	0,806	28-juin	180	1,128	28-juin	180	1,419
6-juil	188	1,504	6-juil	188	1,613	6-juil	188	2,106
13-juil	195	2,641	20-juil	202	3,395	19-juil	201	3,290
29-juil	211	3,500	10-août	223	3,749	9-août	222	3,718
13-sept	257	2,396				15-sept	259	2,333
std(LAI)			std(LAI)			std(LAI)		
	144	0		144	0		144	0
	174	0,090		174	0,059		174	0,149
	180	0,173		180	0,190		180	0,269
	188	0,196		188	0,289		188	0,368
	195	0,284		202	0,360		201	0,321
	211	0,353		223	0,521		222	0,339
	238	0,442		251	0,411		259	0,528
	257	0,376						



**Annexe 4A : Carte des élévations du champ de maïs
(Point zéro : 89 m au-dessus du niveau de la mer)**



**Annexe 4B : Carte des élévations du champ de soya
(Point zéro : 69 m au-dessus du niveau de la mer)**

Annexe 4C : Corrélation entre les rendements du maïs et les paramètres du sol

	Élévation	Pente	Orientation	P	K	PH	MO	MG	CEC	CA
Rend. C.	0,253*	-0,502*	-0,136*	-0,223*	-0,482*	-0,574*	0,582*	0,012*	0,288*	0,288*
Élévation	1	-0,466*	-0,021	-0,527*	-0,407*	-0,197*	0,126*	0,563*	0,571*	0,551*
Pente	-0,466*	1	0,093*	0,257*	0,433*	0,170*	-0,391*	-0,170*	-0,375*	-0,421*
Orientation	-0,021	0,093*	1	0,002	0,079	0,093*	-0,189*	0,126*	0,065	0,067
P	-0,527*	0,257*	0,002	1	0,802*	0,286*	-0,189*	-0,598*	-0,699*	-0,713*
K	-0,407*	0,433*	0,079	0,802*	1	0,223*	-0,508*	-0,339*	-0,630*	-0,728*
PH	-0,197*	0,170*	0,093*	0,286*	0,223*	1	-0,356*	-0,235*	-0,333*	-0,130*
MO	0,126*	-0,391*	-0,189*	-0,189*	-0,508*	-0,356*	1	-0,136*	0,333*	0,413*
MG	0,563*	-0,170*	0,126*	-0,598*	-0,339*	-0,235*	-0,136*	1	0,819*	0,680*
CEC	0,571*	-0,375*	0,065	-0,699*	-0,630*	-0,333*	0,333*	0,819*	1	0,946*
CA	0,551*	-0,421*	0,067	-0,713*	-0,728*	-0,130*	0,413*	0,680*	0,946*	1

*Corrélations significatives à 95% (Rend. C. = rendement corrigé)

Annexe 4D: Corrélation entre les rendements du soya et les paramètres du sol

	Élévation	Pente	Orientation	PH	P	MO	MG	K	CEC	CA
Rend. C.	0,070	0,101	0,200*	-0,428*	-0,297*	-0,222*	-0,322*	-0,319*	0,114*	-0,384*
Élévation	1	0,144*	-0,029	0,220*	-0,390*	-0,629*	-0,203*	-0,766*	-0,665*	-0,089
Pente	0,144*	1	0,177*	-0,181*	-0,191*	-0,311*	-0,299*	-0,169*	-0,359*	-0,401*
Orientation	-0,029	0,177*	1	-0,091	0,152*	0,032	0,087	0,101	0,032	-0,119*
PH	0,220*	-0,181*	-0,091	1	-0,020	0,307*	0,768*	-0,080	-0,146*	0,832*
P	-0,390*	-0,191*	0,152*	-0,020	1	0,477*	0,258*	0,669*	0,415*	0,237*
MO	-0,629*	-0,311*	0,032	0,307*	0,477*	1	0,671*	0,592*	0,795*	0,685*
MG	-0,203*	-0,299*	0,087	0,768*	0,258*	0,671*	1	0,191*	0,319*	0,806*
K	-0,766*	-0,169*	0,101	-0,080	0,669*	0,592*	0,191*	1	0,554*	0,237*
CEC	-0,665*	-0,359*	0,032	-0,146*	0,415*	0,795*	0,319*	0,554*	1	0,350*
CA	-0,089	-0,401*	-0,119*	0,832*	0,237*	0,685*	0,806*	0,237*	0,350*	1

*Corrélations significatives à 95%

Annexe 4E : Modèles de régression multiple entre les rendements et les réflectances
a) Canaux rouges (21 juillet)

R = 0,443 ; R ² = 0,196 ; R ² ajusté = 0,188 F(1, 98) = 23,93; p < 0,00000; erreur sur l'estimé : 0,828 (n = 100)						
	Beta	Erreur Beta	B	Erreur sur B	t (98)	p
Origine			11,401	0,401	28,452	0,000
647 nm	-0,443	0,091	-33,789	6,907	-4,892	0,000

b) Canaux PIR (21 juillet)

R = 0,676 ; R ² = 0,458 R ² ajusté = 0,435 F(4, 95) = 20,08; p < 0,00000; erreur sur l'estimé : 0,69 (n = 100)						
	Beta	Erreur Beta	B	Erreur sur B	t (98)	p
Origine			5,992	2,196	2,729	0,008
900 nm	0,634	0,221	20,328	7,074	2,874	0,005
746 nm	-0,432	0,186	-21,485	9,251	-2,323	0,022
876 nm	1,091	0,466	25,078	10,713	2,341	0,021
781 nm	-0,825	0,485	-19,978	11,757	-1,699	0,093

c) Canaux rouges (13 septembre)

R = 0,278; R ² = 0,077; R ² ajusté = 0,049 F(3, 96) = 2,693; p < 0,05; erreur sur l'estimé : 0,896 (n = 100)						
	Beta	Erreur Beta	B	Erreur sur B	t (98)	p
Origine			5,992	2,196	2,729	0,008
647 nm	-1,966	0,695	-225,807	79,870	-2,827	0,006
657 nm	1,331	0,894	149,993	100,814	1,488	0,140

d) Canaux PIR (13 septembre)

R = 0,518; R ² = 0,268; R ² ajusté = 0,238 F(4, 95) = 8,72 ; p < 0,0000; erreur sur l'estimé : 0,803 (n = 100)						
	Beta	Erreur Beta	B	Erreur sur B	t (95)	p
Origine			8,042	1,134	7,093	0,000
746 nm	1,242	0,520	42,534	17,816	2,387	0,019
876 nm	-2,702	0,607	-104,442	23,447	-4,454	0,000
721 nm	0,418	0,149	25,710	9,185	2,799	0,006
801 nm	1,565	0,795	49,399	25,096	1,968	0,052

**Annexe 4F : Corrélation entre les rendements du maïs, les IV et les IT
(21 juillet 1998, n = 400)**

	Rend. NC	Rend. C	NDVI	SAVI	TSARVI	WDVI	HOM	CON	ENT	SMA
Rend. C.	0,595*	1	0,533*	0,618*	0,631*	0,525*	0,458*	-0,129*	-0,428*	0,355*
NDVI	0,417*	0,533*	1	0,845*	0,855*	0,888*	0,608*	-0,432*	-0,588*	0,489*
SAVI	0,417*	0,618*	0,845*	1	0,990*	0,854*	0,759*	-0,570*	-0,739*	0,629*
TSARVI	0,419*	0,631*	0,855*	0,990*	1	0,836*	0,755*	-0,576*	-0,737*	0,623*
WDVI	0,397*	0,525*	0,888*	0,854*	0,836*	1	0,594*	-0,371*	-0,579*	0,497*
HOM	0,346*	0,458*	0,608*	0,759*	0,755*	0,594*	1	-0,750*	-0,984*	0,928*
CON	-0,141*	-0,129*	-0,432*	-0,570*	-0,576*	-0,371*	-0,750*	1	0,758*	-0,581*
ENT	-0,323*	-0,428*	-0,588*	-0,739*	-0,737*	-0,579*	-0,984*	0,758*	1	-0,945*
SMA	0,263*	0,355*	0,489*	0,629*	0,623*	0,497*	0,928*	-0,581*	-0,945*	1

* Coefficients de corrélation significatifs à 95%

**Annexe 4G:Corrélation entre les rendements du maïs, les IV et les IT
(16 septembre 1998, n = 400)**

	Rend. NC	Rend. C	NDVI	SAVI	TSARVI	WDVI	HOM	CON	ENT	SMA
Rend. C.	0,595*	1	0,037	0,064	0,209*	0,107*	0,125*	-0,098*	-0,153*	0,142*
NDVI	0,060	0,037	1	0,973*	0,719*	0,809*	0,081	-0,180*	-0,081	0,041
SAVI	0,066	0,064	0,973*	1	0,720*	0,923*	0,130*	-0,210*	-0,124*	0,080
TSARVI	0,063	0,209*	0,719*	0,720*	1	0,638*	0,186*	-0,246*	-0,205*	0,139*
WDVI	0,069	0,107*	0,809*	0,923*	0,638*	1	0,192*	-0,229*	-0,177*	0,134*
HOM	0,082	0,125*	0,081	0,130*	0,186*	0,192*	1	-0,750*	-0,957*	0,911*
CON	-0,057	-0,098*	-0,180*	-0,210*	-0,246*	-0,229*	-0,750*	1	0,696*	-0,525*
ENT	-0,099	-0,153*	-0,081	-0,124*	-0,205*	-0,177*	-0,957*	0,696*	1	-0,963*
SMA	0,093	0,142*	0,041	0,080	0,139*	0,134*	0,911*	-0,525*	-0,963*	1

* Coefficients de corrélation significatifs à 95%

**Annexe 4H : Corrélation entre les rendements du soya, les IV et les IT
(30 juillet 1997, n = 300)**

	Rend. NC	Rend. C	NDVI	SAVI	HOM	CON	ENT	SMA
Rend. C.	0,403*	1	0,434*	0,434*	-0,180*	0,038	-0,039	-0,098
NDVI	0,109*	0,434*	1	1,00*	0,119*	-0,283*	-0,510*	0,232*
SAVI	0,195*	0,434*	1,00*	1	0,119*	-0,283*	-0,510*	0,232*
HOM	-0,130	-0,180*	0,119*	0,119*	1	-0,833*	-0,786*	0,924*
CON	0,063	0,038	-0,283*	-0,283*	-0,833*	1	0,798*	-0,741/
ENT	0,013	-0,039	-0,510*	-0,510*	-0,786*	0,798*	1	-0,860*
SMA	-0,074	-0,098	0,232*	0,232*	0,924*	-0,741*	-0,860*	1

* Coefficients de corrélation significatifs à 95%; Rend. NC = rendement non corrigé.

**Annexe 4I : Corrélation entre les rendements du soya, les IV et les IT
(5 septembre 1997, n = 300)**

	Rend. NC	Rend. C	NDVI	SAVI	HOM	CON	ENT	SMA
Rend. C.	0,403*	1	0,199*	0,283*	0,267*	-0,233*	-0,352*	0,317*
NDVI	0,171*	0,199*	1	0,432*	0,369*	-0,398*	-0,482*	0,352*
SAVI	0,153*	0,283*	0,432*	1	0,453*	-0,537*	-0,539*	0,371*
HOM	0,110*	0,267*	0,369*	0,453*	1	-0,876*	-0,936*	0,921*
CON	-0,110*	-0,233*	-0,398*	-0,537*	-0,876*	1	0,877*	-0,692*
ENT	-0,165*	-0,352*	-0,482*	-0,539*	-0,936*	0,877*	1	-0,907*
SMA	0,140*	0,317*	0,352*	0,371*	0,921*	-0,692*	-0,907*	1

* Coefficients de corrélation significatifs à 95%

Annexe 5A : Analyse de variance (ANOVA) des zones d'azote (21 juillet)

	Variance	Sommes des carrées	df	Moyenne au carrée	F	p < 0,05
NDVI	expliquée	0,16	2	0,082	25,993	0,0000
	résiduelle	2,32	739	0,003		
	Total	2,49	741			
SAVI	expliquée	0,21	2	0,103	46,367	0,0000
	résiduelle	1,64	739	0,002		
	Total	1,85	741			
TSARVI	expliquée	0,13	2	0,066	36,800	0,0000
	résiduelle	1,33	739	0,002		
	Total	1,46	741			
WDVI	expliquée	0,76	2	0,382	131,533	0,0000
	résiduelle	2,14	739	0,003		
	Total	2,91	741			
HOM	expliquée	1,35	2	0,677	39,850	0,0000
	résiduelle	12,55	739	0,017		
	Total	13,91	741			
CON	expliquée	150,97	2	75,485	23,947	0,0000
	résiduelle	2329,50	739	3,152		
	Total	2480,48	741			
ENT	expliquée	51,07	2	25,537	33,530	0,0000
	résiduelle	562,84	739	0,762		
	Total	613,91	741			
SMA	expliquée	9,46	2	4,729	18,483	0,0000
	résiduelle	189,07	739	0,256		
	Total	198,53	741			

Annexe 5B : Analyse de variance (ANOVA) des zones d'azote (13 septembre)

	Variance	Sommes des carrées	df	Moyenne au carrée	F	p < 0,05
NDVI	expliquée	0,70	2	0,348	223,24	0,0000
	résiduelle	1,15	739	0,002		
	Total	1,85	741			
SAVI	expliquée	0,46	2	0,228	168,92	0,0000
	résiduelle	1,00	739	0,001		
	Total	1,45	741			
TSARVI	expliquée	0,23	2	0,115	240,01	0,0000
	résiduelle	0,35	739	0,000		
	Total	0,58	741			
WDVI	expliquée	0,35	2	0,176	245,99	0,0000
	résiduelle	0,53	739	0,001		
	Total	0,88	741			
HOM	expliquée	0,48	2	0,238	50,25	0,0000
	résiduelle	3,50	739	0,005		
	Total	3,97	741			
CON	expliquée	12,27	2	6,137	22,86	0,0000
	résiduelle	198,44	739	0,269		
	Total	210,72	741			
ENT	expliquée	29,65	2	14,824	50,25	0,0000
	résiduelle	218,00	739	0,295		
	Total	247,65	741			
SMA	expliquée	23,75	2	11,876	54,58	0,0000
	résiduelle	160,79	739	0,218		
	Total	184,54	741			

Annexes 6A : Extraction des composantes principales (juillet – septembre - maïs)**1. Composantes principales du modèle MLP1 (IV)**

Composante principale	Valeur propre	Variance totale (%)	Valeur cumulée	Variance cumulée (%)
1*	3,888	48,612	3,889	48,612
2*	3,724	46,555	7,613	95,167
3	0,255	3,193	7,869	98,360
4	0,082	1,025	7,951	99,385
5	0,028	0,356	7,979	99,741
6	0,021	0,256	8,000	99,998
7	0	0,002	8	100
8	0	0	8	100

2. Composantes principales du modèle MLP2 (IT)

Composante principale	Valeur propre	Variance totale (%)	Valeur cumulée	Variance cumulée (%)
1*	3,771	47,148	3,772	47,148
2*	3,202	40,026	6,974	87,174
3	0,471	5,886	7,445	93,060
4	0,431	5,383	7,875	98,443
5	0,055	0,681	7,930	99,124
6	0,047	0,585	7,977	99,709
7	0,013	0,165	7,990	99,874
8	0,010	0,126	8	100

3. Composantes du modèle MLP3 (IT - IV)

Composante principale	Valeur propre	Variance totale (%)	Valeur cumulée	Variance cumulée (%)
1*	6,365	39,787	6,366	39,787
2*	4,058	25,366	10,424	65,153
3*	3,052	19,077	13,477	84,230
4*	1,169	7,307	14,646	91,537
5	0,469	2,932	15,115	94,469
6	0,395	2,469	15,510	96,938
7	0,250	1,560	15,760	98,498
8	0,082	0,513	15,842	99,011
9	0,052	0,326	15,894	99,337
10	0,034	0,215	15,928	99,552
11	0,028	0,177	15,957	99,729
12	0,020	0,126	15,977	99,856
13	0,013	0,082	15,990	99,937
14	0,010	0,061	16,000	99,999
15	0	0,001	16	100

*composantes significatives selon la règle de Kaiser

Annexes 6B : Extraction des composantes principales (juillet – septembre - soya)**1. Composantes du modèle MLP1 (IV)**

Composante principale	Valeur propre	Variance totale (%)	Valeur cumulée	Variance cumulée (%)
1*	2,693	67,323	2,693	67,323
2*	1,280	20,123	3,498	87,447
3	0,502	12,553	4	100
4	0	0	4	100

2. Composantes du modèle MLP2 (IT)

Composante principale	Valeur propre	Variance totale (%)	Valeur cumulée	Variance cumulée (%)
1*	3,938	49,228	3,938	49,228
2*	3,268	40,853	7,206	90,081
3	0,311	3,884	7,517	93,965
4	0,239	2,986	7,756	96,951
5	0,144	1,795	7,900	98,746
6	0,052	0,644	7,951	99,390
7	0,033	0,418	7,985	99,807
8	0,015	0,193	8	100

3. Composantes du modèle 3 (IV - IT)

Composante principale	Valeur propre	Variance totale (%)	Valeur cumulée	Variance cumulée (%)
1*	5,410	45,085	5,410	45,085
2*	3,347	27,893	8,757	72,979
3*	1,280	10,667	10,037	83,646
4	0,768	6,398	10,805	90,044
5	0,509	4,242	11,314	94,285
6	0,277	2,309	11,591	96,595
7	0,212	1,771	11,804	98,366
8	0,105	0,873	11,909	99,238
9	0,045	0,372	11,953	99,610
10	0,032	0,268	11,985	99,878
11	0,015	0,122	12	100

*Composantes significatives selon la règle de Kaiser

Annexe 6C: Sélection des variables à l'aide de l'ADS (juillet - maïs)**1. Variables du modèle MLP1 (IV)**

Step 3, N of vars in model: 3; Grouping: CLASSE (3 grps)

Wilks' Lambda: ,28678 approx. F (6,1178)=170,29 p<0,0000

	Wilks' Lambda	Partial Lambda	F-remove (2,589)	p-level	Toler.	1-Toler. (R-Sqr.)
TSARVI	0,481	0,596	199,857	0	0,431	0,569
WDVI	0,313	0,915	27,371	4,299E-12	0,209	0,791
NDVI	0,305	0,941	18,532	1,566E-08	0,200	0,800

2. Variables du modèle MLP2 (IT)

Step 4, N of vars in model: 4; Grouping: CLASSE (3 grps)

Wilks' Lambda: ,19922 approx. F (8,1176)=182,34 p<0,0000

	Wilks' Lambda	Partial Lambda	F-remove (2,588)	p-level	Toler.	1-Toler. (R-Sqr.)
HOM	0,271	0,734	106,544	0	0,054	0,946
CON	0,364	0,548	242,913	0	0,253	0,747
SMA	0,265	0,751	97,614	0	0,099	0,901
ENT	0,227	0,879	40,416	3,578E-17	0,031	0,969

3. Variables du modèle MLP3 (IV-IT)

Step 6, N of vars in model: 6; Grouping: CLASSE (3 grps)

Wilks' Lambda: ,1458 approx. F (12,1172)=1158,1 p<0,0000

	Wilks' Lambda	Partial Lambda	F-remove (2,585)	p-level	Toler.	1-Toler. (R-Sqr.)
TSARVI	0,168	0,809	69,120	1,129E-27	0,311	0,689
CON	0,218	0,624	176,322	0	0,223	0,777
HOM	0,172	0,790	77,521	1,366E-30	0,050	0,950
SMA	0,160	0,849	52,064	1,551E-21	0,098	0,902
ENT	0,151	0,899	32,896	2,892E-14	0,031	0,969
WDVI	0,156	0,873	42,585	5,422E-18	0,177	0,823

4. Variables du modèle MLP4 (IV-IT-TOPO)

Step 8, N of vars in model: 8; Grouping: CLASSE (3 grps)

Wilks' Lambda: ,0922 approx. F (16,1168)=167,35 p<0,0000

	Wilks' Lambda	Partial Lambda	F-remove (2,582)	p-level	Toler.	1-Toler. (R-Sqr.)
TSARVI	0,109	0,813	66,946	6,789E-27	0,308	0,692
Élévation	0,118	0,749	97,269	0	0,767	0,233
Pente	0,092	0,963	11,327	1,493E-05	0,860	0,140
CON	0,123	0,721	112,564	0	0,217	0,783
HOM	0,108	0,819	64,455	5,183E-26	0,043	0,957
ENT	0,101	0,877	40,730	2,784E-17	0,028	0,972
SMA	0,099	0,899	32,846	3,052E-14	0,093	0,907
Orientation	0,093	0,956	13,321	2,204E-06	0,959	0,041

Annexe 6D: Sélection des variables à l'aide de l'ADS (juil-sept-maïs)

1. Variables du modèle MLP1 (IV)

Step 7, N of vars in model: 7; Grouping: CLASSE (3 grps)						
Wilks' Lambda: ,16329 approx. F (14,1170)=123,24 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,585)	p-level	1-Toler. Toler.	(R-Sqr.)
TSARVI_J	0,268	0,609	187,517	0	0,428	0,572
WDVI_S	0,181	0,900	32,384	4,584E-14	0,006	0,994
SAVI_S	0,173	0,945	17,105	6,031E-08	0,001	0,999
TSARVI_S	0,175	0,931	21,668	8,353E-10	0,379	0,621
NDVI_S	0,169	0,965	10,606	2,989E-05	0,002	0,998
WDVI_J	0,170	0,963	11,308	1,519E-05	0,197	0,803
NDVI_J	0,169	0,964	10,851	2,359E-05	0,196	0,804

2. Variables du modèle MLP2 (IT)

Step 7, N of vars in model: 7; Grouping: CLASSE (3 grps)						
Wilks' Lambda: ,17956 approx. F (14,1170)=113,65 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,585)	p-level	1-Toler. Toler.	(R-Sqr.)
HOM_J	0,251	0,715	116,459	0	0,052	0,948
CON_J	0,332	0,540	248,892	0	0,237	0,763
SMA_J	0,237	0,759	92,995	0	0,094	0,906
ENT_J	0,201	0,895	34,225	8,78E-15	0,030	0,970
CON_S	0,187	0,958	12,836	3,502E-06	0,334	0,666
HOM_S	0,184	0,974	7,851	0,0004319	0,076	0,924
ENT_S	0,182	0,985	4,410	0,0125673	0,087	0,913

3. Variables du modèle MLP3 (IV-IT)

Step 11, N of vars in model: 11; Grouping: CLASSE (3 grps)						
Wilks' Lambda: ,07942 approx. F (22,1162)=134,89 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,580)	p-level	1-Toler. Toler.	(R-Sqr.)
TSARVI_J	0,091	0,847	52,334	1,273E-21	0,308	0,692
WDVI_S	0,086	0,902	31,562	9,745E-14	0,006	0,994
SAVI_S	0,082	0,943	17,600	3,795E-08	0,001	0,999
CON_J	0,127	0,608	186,886	0	0,212	0,788
HOM_J	0,099	0,784	79,782	0	0,048	0,952
SMA_J	0,090	0,856	48,933	2,303E-20	0,095	0,905
ENT_J	0,085	0,914	27,440	4,108E-12	0,031	0,969
TSARVI_S	0,080	0,962	11,384	1,415E-05	0,333	0,667
WDVI_J	0,084	0,923	24,330	7,135E-11	0,167	0,833
NDVI_J	0,081	0,958	12,725	3,904E-06	0,183	0,817
NDVI_S	0,081	0,960	12,064	7,356E-06	0,002	0,998

Annexe 6E: Sélection des variables à l'aide de l'ADS (juillet - soya)

1. Variables du modèle MLP1 (IV)

Step 2, N of vars in model: 2; Grouping: CLASSES (3 grps)						
Wilks' Lambda: , 74771 approx. F (4,532)=20,810 p< ,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,266)	p-level	Toler.	1-Toler. (R-Sqr.)
SAVI_J	0,804	0,929	10,094	5,9497E-05	0,692	0,308
NDVI_J	0,781	0,957	5,958	0,00294408	0,692	0,308

2. Variables du modèle MLP2 (IT)

Step 2, N of vars in model: 2; Grouping: CLASSES (3 grps)						
Wilks' Lambda: , 82819 approx. F (4,532)=13,146 p< ,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,266)	p-level	Toler.	1-Toler. (R-Sqr.)
HOM_J	0,969	0,855	22,640	8,3187E-10	0,311	0,689
ENT_J	0,956	0,867	20,455	5,4542E-09	0,311	0,689

3. Variables du modèle MLP 3 (IV-IT)

Step 3, N of vars in model: 3; Grouping: CLASSES (3 grps)						
Wilks' Lambda: , 70174 approx. F (6,530)=17,114 p< ,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,265)	p-level	Toler.	1-Toler. (R-Sqr.)
SAVI_J	0,7682	0,9135	12,5519	6,1907E-06	0,668	0,332
HOM_J	0,7477	0,9385	8,6795	0,00022328	0,965	0,035
NDVI_J	0,7277	0,9643	4,9057	0,00809013	0,688	0,312

4. Variables du modèle MLP4 (IV-IT-TOPO)

Step 6, N of vars in model: 6; Grouping: CLASSES (3 grps)						
Wilks' Lambda: , 54506 approx. F (12,524)=15,480 p< ,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,262)	p-level	Toler.	1-Toler. (R-Sqr.)
SAVI_J	0,562	0,970	4,102	0,01761416	0,602	0,398
Pente	0,597	0,913	12,534	6,3297E-06	0,878	0,122
Orientation	0,610	0,894	15,550	4,1548E-07	0,874	0,126
HOM_J	0,575	0,948	7,188	0,00091432	0,962	0,038
Élévation	0,563	0,969	4,249	0,01526805	0,812	0,188
NDVI_J	0,563	0,969	4,213	0,0158127	0,613	0,387

Annexe 6F: Sélection des variables à l'aide de l'ADS (juillet – septembre -soya)**1. Variables du modèle MLP1 (IV)**

Step 3, N of vars in model: 3; Grouping: CLASSES (3 grps)

Wilks' Lambda: 71629 approx. F (6,530)=16,037 p<,0000

	Wilks' Lambda	Partial Lambda	F-remove (2,265)	p-level	Toler.	1-Toler. (R-Sqr.)
SAVI_J	0,754	0,950	6,947	0,00115	0,511	0,489
NDVI_J	0,750	0,955	6,206	0,00232	0,687	0,313
SAVI_S	0,748	0,958	5,812	0,00339	0,692	0,308

2. Variables du modèle MLP2 (IT)

Step 4, N of vars in model: 4; Grouping: CLASSES (3 grps)

Wilks' Lambda: 68752 approx. F (8,528)=13,598 p<,0000

	Wilks' Lambda	Partial Lambda	F-remove (2,264)	p-level	Toler.	1-Toler. (R-Sqr.)
ENT_S	0,809	0,850	23,254	4,99E-10	0,121	0,879
HOM_S	0,775	0,888	16,710	1,468E-07	0,109	0,891
HOM_J	0,726	0,947	7,456	0,0007077	0,941	0,059
SMA_S	0,709	0,969	4,190	0,0161709	0,221	0,779

3. Variables du modèle MLP3 (IV-IT)

Step 4, N of vars in model: 4; Grouping: CLASSES (3 grps)

Wilks' Lambda: 67293 approx. F (8,528)=14,456 p<,0000

	Wilks' Lambda	Partial Lambda	F-remove (2,264)	p-level	Toler.	1-Toler. (R-Sqr.)
SAVI_J	0,717	0,938	8,736	0,00021	0,501	0,499
HOM_J	0,716	0,939	8,507	0,00026	0,964	0,036
SAVI_S	0,702	0,959	5,653	0,00395	0,692	0,308
NDVI_J	0,699	0,962	5,197	0,00612	0,684	0,316

4. Variables du modèle MLP4 (IV-IT-TOPO)

Step 6, N of vars in model: 6; Grouping: CLASSES (3 grps)

Wilks' Lambda: 54506 approx. F (12,524)=15,480 p<,0000

	Wilks' Lambda	Partial Lambda	F-remove (2,262)	p-level	Toler.	1-Toler. (R-Sqr.)
SAVI_J	0,5621	0,9696	4,1020	0,0176142	0,602	0,398
Pente	0,5972	0,9127	12,5342	6,33E-06	0,878	0,122
Orientation	0,6098	0,8939	15,5496	4,155E-07	0,874	0,126
HOM_J	0,5750	0,9480	7,1876	0,0009143	0,962	0,038
Élévation	0,5627	0,9686	4,2495	0,015268	0,812	0,188
NDVI_J	0,5626	0,9688	4,2133	0,0158127	0,613	0,387

Annexe 6G : Statistiques Z des R^2 entre les rendements prédits et observés

1. Effet de la méthode de réduction des variables (maïs)

Modèle	R^2	r	z	n	Comparaison	Z
MLP1 _{ACP}	0,65	0,806	1,116	230	MLP1 _{ACP} -MLP1 _{ADS}	0,187
MLP1 _{ADS}	0,64	0,800	1,099	230		
MLP2 _{ACP}	0,64	0,800	1,099	230	MLP2 _{ACP} -MLP2 _{ADS}	5,759
MLP2 _{ADS}	0,86	0,927	1,639	230		
MLP3 _{ACP}	0,81	0,90	1,472	230	MLP3 _{ACP} -MLP3 _{ADS}	4,934
MLP3 _{ADS}	0,92	0,96	1,935	230		

2. Effet de la méthode de réduction des variables (soya)

Modèle	R^2	r	z	n	Comparaison	Z
MLP1 _{ACP}	0,21	0,46	0,495	190	MLP1 _{ACP} -MLP1 _{ADS}	0,395
MLP1 _{ADS}	0,24	0,49	0,536	190		
MLP2 _{ACP}	0,26	0,51	0,563	190	MLP2 _{ACP} -MLP2 _{ADS}	0,128
MLP2 _{ADS}	0,27	0,52	0,576	190		
MLP3 _{ACP}	0,36	0,60	0,693	190	MLP3 _{ACP} -MLP3 _{ADS}	0,891
MLP3 _{ADS}	0,43	0,66	0,79	190		

3. Effet de la date d'acquisition de l'image (maïs)

Modèle	R^2	r	z	n	Comparaison	Z
MLP1 _{juil-sept.}	0,65	0,806	1,116	230	MLP1 _{juil-sept.} -MLP1 _{juil.}	1,663
MLP1 _{juil.}	0,73	0,854	1,272	230		
MLP2 _{juil-sept.}	0,86	0,927	1,639	230	MLP2 _{juil-sept.} -MLP2 _{juil.}	1,779
MLP2 _{juil.}	0,81	0,900	1,472	230		
MLP3 _{juil-sept.}	0,92	0,96	1,935	230	MLP3 _{juil-sept.} -MLP3 _{juil.}	1,782
MLP3 _{juil.}	0,89	0,94	1,768	230		

4. Effet de la date d'acquisition de l'image (soya)

Modèle	R^2	r	z	n	Comparaison	Z
MLP1 _{juil-sept.}	0,24	0,490	0,536	190	MLP1 _{juil-sept.} -MLP1 _{juil.}	0
MLP1 _{juil.}	0,24	0,490	0,536	190		
MLP2 _{juil-sept.}	0,27	0,520	0,576	190	MLP2 _{juil-sept.} -MLP2 _{juil.}	0
MLP2 _{juil.}	0,27	0,520	0,576	190		
MLP3 _{juil-sept.}	0,43	0,66	0,785	190	MLP3 _{juil-sept.} -MLP3 _{juil.}	0,385
MLP3 _{juil.}	0,40	0,63	0,745	190		

5. Effet de l'intégration de la topographie dans le modèle (maïs)

Modèle	R ²	r	z	n	Comparaison	Z
MLP3 _{juil-sept.}	0,92	0,96	1,935	213	MLP3 _{ADS} -MLP4 _{ADS}	0,71
MLP4 _{juil-sept.}	0,93	0,96	2,005	213		
MLP3 _{juil.}	0,89	0,94	1,768	214	MLP3 _{ADS} -MLP4 _{ADS}	1,72
MLP4 _{juil.}	0,92	0,96	1,935	213		

6. Effet de l'intégration de la topographie dans le modèle (soya)

Modèle	R ²	r	z	n	Comparaison	Z
MLP3 _{juil-sept.}	0,43	0,66	0,785	213	MLP3 _{juil-sept.} - MLP4 _{juil-sept.}	2,86
MLP4 _{juil-sept.}	0,62	0,79	1,065	213		
MLP3 _{juil.}	0,40	0,63	0,745	214	MLP3 _{juil.} - MLP4 _{juil.}	3,27
MLP4 _{juil.}	0,62	0,79	1,065	213		

Annexe 7A: Extraction des composantes principales (juillet - septembre)

1. Composantes principales du modèle MLP3 (IV - IT)

Composante principale	Valeur propre	Variance totale (%)	Valeur cumulée	Variance cumulée (%)
1*	6,227	38,920	6,227	38,920
2*	3,288	20,550	9,515	59,470
3*	3,058	19,112	12,573	78,582
4*	1,433	8,958	14,006	87,539
5	0,541	3,380	14,547	90,919
6	0,465	2,906	15,012	93,825
7	0,359	2,246	15,371	96,071
8	0,298	1,860	15,669	97,930
9	0,164	1,022	15,832	98,953
10	0,066	0,416	15,899	99,368
11	0,040	0,248	15,939	99,617
12	0,027	0,169	15,966	99,786
13	0,014	0,089	15,980	99,874
14	0,011	0,071	15,991	99,945
15	0,008	0,052	16	99,997
16	0	0,003	16	100

*composante significative selon la règle de Kaiser

2. Composantes principales du modèle MLP4 (IV – IT - TOPO)

Composante principale	Valeur propre	Variance totale (%)	Valeur cumulée	Variance cumulée (%)
1*	6,469	34,046	6,469	34,046
2*	3,320	17,475	9,789	51,521

3*	3,128	16,464	12,917	67,985
4*	2,186	11,503	15,103	79,488
5*	1,214	5,142	16,080	84,630
6	0,833	4,386	16,913	89,016
7	0,537	2,826	17,450	91,842
8	0,496	2,608	17,946	94,450
9	0,359	1,889	18,304	96,339
10	0,301	1,584	18,606	97,924
11	0,164	0,861	18,769	98,785
12	0,071	0,372	18,840	99,157
13	0,062	0,328	18,902	99,485
14	0,039	0,205	18,941	99,690
15	0,026	0,138	18,967	99,828
16	0,014	0,072	18,981	99,900
17	0,011	0,058	18,992	99,958
18	0,008	0,040	19	99,998
19	0	0,002	19	100

*composante significative selon la règle de Kaiser

Annexe 7B: Sélection des variables à l'aide de l'ADS (juillet - septembre)

1. Variables du modèle MLP3 (IV - IT)

Step 7, N of vars in model: 7; Grouping: ZONES (3 grps)						
Wilks' Lambda: ,05984 approx. F (14,1466)=323,34 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove -2,733	p-level	Toler.	1-Toler. (R-Sqr.)
WDVI_S	0,073	0,815	83,253	0	0,007	0,993
SAVI_S	0,067	0,900	40,928	0	0,001	0,999
WDVI_J	0,079	0,756	118,045	0	0,148	0,852
NDVI_J	0,072	0,833	73,485	0	0,146	0,854
TSARVI_S	0,071	0,843	68,170	0	0,627	0,373
ENT_S	0,066	0,912	35,519	0	0,920	0,080
NDVI_S	0,065	0,924	30,316	0	0,003	0,997

2. Variables du modèle MLP4 (IV – IT - TOPO)

Step 11, N of vars in model: 11; Grouping: ZONES (3 grps)						
Wilks' Lambda: ,03681 approx. F (22,1458)=279,15 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,729)	p-level	Toler.	1-Toler. (R-Sqr.)
Élévation	0,052	0,705	152,160	0	0,613	0,387
TSARVI_S	0,044	0,842	68,530	5,34E-28	0,586	0,414
WDVI_J	0,044	0,841	68,756	4,42E-28	0,133	0,867
NDVI_J	0,042	0,870	54,533	8,5E-23	0,139	0,861
CON_S	0,039	0,935	25,483	2,01E-11	0,850	0,150
WDVI_S	0,042	0,877	51,323	1,4E-21	0,006	0,994
SAVI_S	0,040	0,923	30,424	2,04E-13	0,001	0,999
NDVI_S	0,039	0,936	25,041	3,04E-11	0,003	0,997
Pente	0,039	0,934	25,801	1,49E-11	0,832	0,168
CON_J	0,041	0,906	37,955	2,09E-16	0,366	0,634
TSARVI_J	0,039	0,949	19,405	6,16E-09	0,215	0,785

Annexe 7C: Sélection des variables à l'aide de l'ADS (juillet)

1. Variables du modèle MLP1 (IV)

Step 4, N of vars in model: 4; Grouping: ZONES (3 grps)						
Wilks' Lambda: ,33446 approx. F (8,1472)=134,16 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,736)	p-level	Toler.	1-Toler. (R-Sqr.)
WDVI_J	0,592	0,565	283,088	0	0,139	0,861
NDVI_J	0,472	0,709	151,350	0	0,143	0,857
TSARVI_J	0,429	0,780	103,566	0	0,019	0,981
SAVI_J	0,419	0,798	93,016	0	0,020	0,980

2. Variables du modèle MLP2 (IT)

Step 3, N of vars in model: 3; Grouping: ZONES (3 grps)						
Wilks' Lambda: ,71569 approx. F (6,1474)=44,725 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,737)	p-level	Toler.	1-Toler. (R-Sqr.)
HOM_J	0,928	0,772	109,115	0	0,054	0,946
CON_J	0,875	0,818	81,881	0	0,145	0,855
SMA_J	0,825	0,868	56,234	1,8663E-23	0,139	0,861

3. Variables du modèle MLP3 (IV-IT)

Step 7, N of vars in model: 7; Grouping: ZONES (3 grps)						
Wilks' Lambda: ,28124 approx. F (14,1466)=92,740 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove 2,733	p-level	Toler.	1-Toler. (R-Sqr.)
WDVI_J	0,440	0,639	207,471	0	0,130	0,870
NDVI_J	0,384	0,733	133,492	0	0,140	0,860
HOM_J	0,322	0,874	52,972	3,2555E-22	0,038	0,962
CON_J	0,304	0,925	29,629	4,2254E-13	0,131	0,869
SMA_J	0,306	0,919	32,498	3,0002E-14	0,107	0,893
SAVI_J	0,353	0,796	94,132	0	0,020	0,980
TSARVI_J	0,343	0,819	80,808	0	0,019	0,981

4. Variables du modèle MLP4 (IV – IT - TOPO)

Step 6, N of vars in model: 6; Grouping: ZONES (3 grps)						
Wilks' Lambda: ,10758 approx. F (12,1468)=250,65 p<0,0000						
	Wilks' Lambda	Partial Lambda	F-remove (2,734)	p-level	Toler.	1-Toler. (R-Sqr.)
Élévation	0,253	0,424	497,561	0	0,680	0,320
WDVI_J	0,155	0,693	162,706	0	0,146	0,854
NDVI_J	0,138	0,777	105,214	0	0,142	0,858
Pente	0,126	0,855	62,449	8,9954E-26	0,842	0,158
CON_J	0,119	0,905	38,580	1,1701E-16	0,585	0,415
Orientation	0,111	0,973	10,315	3,819E-05	0,945	0,055

Annexe 7D: Test Z sur les coefficients Kappa

1. Effet de la réduction des variables (juillet - septembre)

Modèle	Kappa	σ	Comparaison	Z
MLP3 _{ACP}	0,50	0,0155	MLP3 _{ACP} - MLP3 _{ADS}	17,91
MLP3 _{ADS}	0,81	0,0077		
MLP4 _{ACP}	0,82	0,0098	MLP4 _{ACP} - MLP4 _{ADS}	11,52
MLP4 _{ADS}	0,95	0,0056		

2. Contribution relative des IV et IT (juillet) (cas de l'ADS)

Modèle	Kappa	σ	Comparaison	Z
MLP1 _{juil.}	0,57	0,0172	MLP1 - MLP2	2,55
MLP2 _{juil.}	0,49	0,0263	MLP1 - MLP3	7,14
MLP3 _{juil.}	0,72	0,0121	MLP2 - MLP3	7,94
MLP4 _{juil.}	0,90	0,0057	MLP3 - MLP4	13,46

3. Effet de l'intégration de la topographie dans le modèle (cas de l'ADS)

Modèle	Kappa	σ	Comparaison	Z
MLP3 _{ACP}	0,50	0,0155	MLP3 _{ACP} - MLP4 _{ACP}	17,45
MLP4 _{ACP}	0,82	0,0098		
MLP3 _{ADS}	0,81	0,0077	MLP3 _{ADS} - MLP4 _{ADS}	14,70
MLP4 _{ADS}	0,95	0,0056		
MLP3 _{juil.}	0,72	0,0121	MLP3 _{juil.} - MLP4 _{juil.}	13,46
MLP4 _{juil.}	0,90	0,0057		

4. Effet de la date d'acquisition de l'image (cas de l'ADS)

Modèle	Kappa	σ	Comparaison	Z
MLP3 _{juil.-sept.}	0,81	0,0077	MLP3 _{juil.} - MLP3 _{juil.-sept.}	6,28
MLP3 _{juil.}	0,72	0,0121		
MLP4 _{juil.-sept.}	0,95	0,0056	MLP4 _{juil.} - MLP4 _{juil.-sept.}	6,26
MLP4 _{juil.}	0,90	0,0057		